

UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA BIOMÉDICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA

JUSCIAANE CHACON VIEIRA

INTERFACE CÉREBRO-MÁQUINA UTILIZANDO O EEG HUMANO: MOVENDO O
AVATAR NUM AMBIENTE VIRTUAL UTILIZANDO ATIVIDADE ELÉTRICA DO
CÉREBRO

Recife
2018

JUSCIAANE CHACON VIEIRA

INTERFACE CÉREBRO-MÁQUINA UTILIZANDO O EEG HUMANO: MOVENDO O
AVATAR NUM AMBIENTE VIRTUAL UTILIZANDO ATIVIDADE ELÉTRICA DO
CÉREBRO

Dissertação submetida ao curso de Pós-Graduação em Engenharia Biomédica da Universidade Federal de Pernambuco, como parte dos requisitos necessários à obtenção do grau de Mestre em Engenharia Biomédica.

Área de concentração: Computação biomédica

Linha de pesquisa: Processamento de biossinais e imagens médicas e biológicas

Orientador: Prof. Dr. Marcelo Cairrão
Araujo Rodrigues

Coorientador: Prof. Dr. Wellington Pinheiro dos Santos

Recife

2018

Catálogo na fonte
Bibliotecária Maria Luiza de Moura Ferreira, CRB-4 / 1469

- V657i Vieira, Jusciaane Chacon.
Interface cérebro-máquina utilizando o EEG humano: movendo o avatar num ambiente virtual utilizando atividade elétrica do cérebro / Jusciaane Chacon Vieira. - 2018.
70 folhas, il., quadros, tab., abr., sigl.

Orientador: Prof. Dr. Marcelo Cairrão Araujo Rodrigues.
Coorientador: Prof. Dr. Wellington Pinheiro dos Santos.
Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Biomédica, 2018.
Inclui Referências.
1. Engenharia Biomédica. 2. Interface cérebro-máquina. 3. Imagética motora. 4. Reconhecimento de padrões. I. Rodrigues, Marcelo Cairrão Araujo (Orientador). II. Santos, Wellington Pinheiro dos (Coorientador). III. Título.

UFPE

610.28 CDD (22. ed.)

BCTG/2018-155

JUSCIAANE CHACON VIEIRA

INTERFACE CÉREBRO-MÁQUINA UTILIZANDO O EEG HUMANO: MOVENDO O
AVATAR NUM AMBIENTE VIRTUAL UTILIZANDO ATIVIDADE ELÉTRICA DO
CÉREBRO

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

Aprovado em: 28/02/2018

Orientador: _____

Prof. Dr. Marcelo Cairrão Araujo Rodrigues,
Doutor pela USP – São Paulo, Brasil

Banca Examinadora:

Prof. Dr. Marcelo Cairrão Araujo Rodrigues, UFPE
Doutor pela USP – São Paulo, Brasil.

Profa. Dra. Rosa Amalia Fireman Dutra, UFPE
Doutora pela UFPE – Recife, Brasil

Prof. Dr. Danilo Alves Pinto Nagem, UFRN
Doutor pela UFMG – Belo Horizonte, Brasil

Recife, fevereiro de 2018.

AGRADECIMENTOS

Agradeço a Deus por permitir e conceder discernimento para chegar até aqui.

Agradeço a minha família pelo apoio, compreensão e conselhos.

Agradeço o meu orientador, professor Dr. Marcelo Cairrão, pelas orientações, confiança depositada e por conduzir essa pesquisa com entusiasmo de um verdadeiro cientista, que acredita nas conquistas e contribuições que podemos alcançar por meio da ciência para sociedade e academia.

Agradeço meu coorientador, professor Dr. Wellington Pinheiro, pelas orientações, paciência, atenção e competência que se mostra por meio dos *insight* que conduziram este trabalho.

Agradeço a Neurobots e sua equipe (Vítor, Júlio e José) pelo suporte, atenção, disponibilidade e contribuição imprescindível.

Agradeço o professor Dr. Anthony Lins por gentilmente esclarecer dúvidas e dar sugestões.

Agradeço os voluntários pela disponibilidade e confiança.

Agradeço o grupo de Neurodinâmica pelo apoio.

Agradeço a FACEPE pelo financiamento.

Agradeço a todos os colegas que, em algum momento, contribuíram com a pesquisa.

Muito obrigada!

RESUMO

Imagética motora é uma atividade mental na qual o sujeito imagina realizar determinado movimento motor, sem executá-lo fisicamente. É uma prática utilizada para controle de próteses mecânica, cadeiras de rodas e na reabilitação de pacientes com lesões neurológicas, técnica que tem apresentado bons resultados referentes a plasticidade neural e aprendizado motor na reabilitação em engenharia biomédica. No entanto, para que seja possível o desenvolvimento de dispositivos controlados pela atividade cerebral, é necessário o estabelecimento de métodos otimizados para coleta e processamento dos dados biológicos, sendo este o objetivo principal do presente trabalho. Por meio do eletroencefalograma (EEG) são adquiridos os sinais neurais, para uso no controle de um dispositivo externo, sem uma requisição da ação muscular. Os sinais de EEG são então submetidos a um processo de aprendizado de máquina, onde se busca avaliar classificadores, após o tratamento do sinal. O tratamento dos dados (pré-processamento, extração de atributos e redução da dimensionalidade) facilita o processo de reconhecimento de padrões dos sinais relacionados à imaginação motora. Neste trabalho foram realizadas classificações de sinais de imagética motora de forma *off-line* e *online*. Foram analisados sinais de uma base de dados disponível e foram coletados sinais de EEG obtidos em experimentos com 4 voluntários. Os dados coletados foram utilizados para mover um avatar com 4 comandos, utilizando da imagética de movimentos de membros superiores e inferiores (imagética de mão esquerda, imagética de mão direita, imagética de pés e parado (sem imagética ou movimento)). Foram avaliados os desempenhos de algumas técnicas para tratar o sinal (dessincronização relacionada ao evento, análise no domínio do tempo, análise do domínio do tempo e frequência e filtragem espacial) e o uso de alguns classificadores (k vizinhos mais próximos, máquina de vetores de suporte, árvore de decisão, *perceptron* de múltiplas camadas, análise de discriminante lineares e ensemble). Os métodos implementados *online* foram capazes de classificar as 4 classes com acurácia de 80% em um dos sujeitos, porém com média de 60,75% para a amostra estudada. Não houve destaque entre os métodos implementados para interface cérebro-máquina (ICM) proposta, como sendo o mais adequado para todos os sujeitos. Dessa forma, foi preferível utilizar um método particular que atingiu os melhores índices para cada sujeito. A quantidade de dados para o treinamento influenciou na capacidade de generalização dos sinais. Utilizando 6 coletas (60 exemplos de cada classe com duração de 5s cada exemplo) na fase de treinamento foi possível obter sucesso na ativação do avatar, em parte da amostra, pois a prática mental de alguns sujeitos influenciou em seu desempenho. Essa prática pode ser aperfeiçoada com *neurofeedback*, que é uma ferramenta comumente utilizada em ICM.

Palavras-chave: Interface cérebro-máquina. Imagética motora. Reconhecimento de padrões.

ABSTRACT

Motor imagery is a mental activity in which the subject imagines to perform certain motor movement, without physically performing it. It is a practice used for the control of mechanical prostheses, wheelchairs and the rehabilitation of patients with neurological injuries, a technique that has a good production of products related to neural plasticity and motor learning in rehabilitation in biomedical engineering. However, for the development of devices controlled by brain activity, it is necessary to establish optimized methods for collecting and processing biological data, which is the main objective of this work. Through electroencephalogram (EEG) are known as neural, for uncontrolled use of an external device, without a requisition of muscle action. The EEG signals are then submitted to a machine learning process, where the aim is to evaluate classifiers after signal processing. Data processing (preprocessing, attribute extraction and dimensionality reduction) facilitates the process of recognizing patterns of signals related to motor imagery. In this work, several signs of motor imagination were performed both off-line and on-line. Signals from a database available and sent by EEG obtained in experiments with 4 volunteers were analyzed. The collected data were used to launch an avatar with 4 commands, using the imagery of upper and lower limb movements (left hand imagery, right hand imagery, feet imagery and nothing (without imagery or movement)). What is what is what is the subject, analyze the time domain, analyze the time domain and frequency and spatial filtering and the use of some classifiers (k-nearest neighbor, support vector machine, decision tree, multilayer perceptron, linear discriminant analysis and ensemble). The methods implemented online are able to classify as 4 classes with 80% capacity in one of the subjects, but with an average of 60.75% for a sample studied. It is not highlighted among the methods implemented for proposed Brain-machine interface (BCI), as being the most suitable for all the subjects. Thus, it was preferable to use a specific method for the best indexes for each subject. An amount of data for the training influenced the generalization capacity of the signals. Using 6 collections (60 examples of each class lasting 5s each example) in the training phase and successfully succeeding in activating the avatar in part of the sample, a mental practice of some subjects influenced their performance. This practice can be improved with neurofeedback, which is a commonly used tool in BCI.

Keywords: Brain-machine interface. Motor imagery. Pattern recognition.

LISTA DE ILUSTRAÇÕES

Figura 1 – Neurônio.....	15
Figura 2 – Homúnculo motor.	17
Figura 3 – 64 Canais de EEG.	35
Figura 4 – Caixa iterativa do EEGLAB para filtragem.	36
Figura 5 – Weka.	37
Figura 6 – Exemplo da saída da aquisição de 1s do sinal bruto.	39
Figura 7 – Protocolo de coleta.	39
Figura 8 – Aplicativo de coleta de dados.	40
Figura 9 – Aplicativo do avatar.	40
Figura 10 – Avatar.	41
Figura 11 – Aplicação <i>online</i>	41
Figura 12 – Protocolo do avatar.	42
Figura 13 – Métodos aplicados nos dados coletados.....	43
Figura 14 – Desempenho da classificação individual com dados da base EEGMMIB	49
Figura 15 – Melhores desempenhos <i>off-line</i> de S1-S4 em 3 janelas de tempo	52
Figura 16 – Desempenho das técnicas com predição <i>online</i> – treinamento.....	54
Figura 17 – Desempenho dos classificadores com predição <i>online</i> – treinamento	55
Figura 18 – Desempenho das técnicas com a predição <i>online</i> – avatar.	56
Figura 19 – Desempenho dos classificadores com predição <i>online</i> – avatar	57

LISTA DE QUADROS

Quadro 1 – Comparação dos trabalhos que utilizaram a base EEGMMIB da PhysioNet.....	28
Quadro 2 – Parâmetro das configurações do classificador no <i>software</i> Weka.....	38
Quadro 3 – Distribuição das coletas	42
Quadro 4 – Configuração dos classificadores	49

LISTA DE TABELAS

Tabela 1 – Resultados do BCI <i>Competition</i>	32
Tabela 2 – Desempenho da classificação individual com dados da base EEGMMIB	50
Tabela 3 – Desempenho da classificação em conjunto com dados da base EEGMMIB	51
Tabela 4 – Matriz de confusão dos dados em conjunto para 64 eletrodos	51
Tabela 5 – Melhores resultados <i>online</i>	58
Tabela 6 – Matrizes de confusão dos melhores desempenhos com o avatar.....	59

LISTA DE ABREVIATURAS E SIGLAS

- AAC: Mudança de Amplitude Média (do inglês *Average Amplitude Change*)
- AAR: Remoção Automática de Artefatos (do inglês *Automatic Artifact Removal*)
- CSP: Padrões Espaciais Comuns (do inglês *Common Spatial Patterns*)
- EEG: Eletroencefalograma/Eletroencefalografia
- EEGMMIDB: Base de Dados de Movimento/Imagética Motor de EEG (do inglês *EEG Motor Movement/Imagery Dataset*)
- ELM: Máquinas de Aprendizado Extremo (do inglês *Extreme Learning Machines*)
- EOG: Eletro-oculografia
- EMG: Eletromiografia
- ERD: Dessincronização Relacionada ao Evento (do inglês *Event-Related Desynchronization*)
- ERS: Sincronização Relacionada ao Evento (do inglês *Event-Related Synchronization*)
- FFT: Transformada Rápida de Fourier (do inglês *Fast Fourier Transform*)
- ICA: Análise de Componentes Independentes (do inglês *Independent Component Analysis*)
- ICM: Interface Cérebro-Máquina
- IEEG: Integral do EEG (do inglês *Integrated EEG*)
- IMD: Imagética de Mão Direita
- IME: Imagética de Mão Esquerda
- IMED: Imagética de Mão Direita e Esquerda
- IPED: Imagética de Pé Direito e Esquerdo
- KNN: K Vizinhos Mais Próximos (do inglês *k-Nearest Neighbor*)
- LDA: Análise de Discriminante Lineares (do inglês *Linear Discriminant Analysis*)
- LOGVAR: Logaritmo da Variância
- LSTM: Memória Longa de Curto Prazo (do inglês *Long Short-Term Memory*)
- MAV: Valor Médio Absoluto (do inglês *Mean Absolute Value*)
- MLP: *Perceptron* de Múltiplas Camadas (do inglês *Multilayer Perceptron*)
- PCA: Análise de Componentes Principais (do inglês *Principal Component Analysis*)
- PSD: Densidade Espectral de Potência (do inglês *Power Spectral Density*)
- RMS: Valor Quadrático Médio (do inglês *Root Mean Square*)

RNN: Rede Neural Recorrente (do inglês *Recurrent Neural Network*)

SSI: Integral Quadrática Simples (do inglês *Simple Square Integral*)

SVM: Máquina de Vetores de Suporte (do inglês *Support Vector Machine*)

TDW: Transformada Discreta de Wavelet

Tree: Árvore de Decisão (do inglês *Decision tree*)

T0: Parado (sem movimento ou imagética motora)

VAR: Variância do EEG (do inglês *Variance of EEG*)

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Motivação e justificativa	13
2	REVISÃO DE LITERATURA.....	15
2.1	Eletroencefalografia e córtex cerebral.....	15
2.2	Interface cérebro-máquina	18
2.2.1	Atividade sensório-motora	18
2.2.2	Métodos de tratamento do sinal.....	19
2.2.3	Aprendizado de máquina	20
2.3	Trabalhos relacionados	21
2.3.1	Base EEGMMIB da PhysioNet	22
2.3.2	BCI <i>Competition</i>	31
3	OBJETIVOS	33
3.1	Gerais.....	33
3.2	Específicos	33
4	METODOLOGIA.....	34
4.1	Descrição dos experimentos	34
4.2	Experimentos com a base EEGMMIB	34
4.3	Experimentos com dados coletados	38
4.3.1	Protocolo dos experimentos	38
4.3.2	Tratamento do sinal	42
5	RESULTADOS E DISCUSSÃO	49
5.1	Classificação da imagética <i>off-line</i>	49
5.2	Classificação da imagética para aplicação em ICM	51
6	CONCLUSÃO.....	60
7	PERSPECTIVAS E CONSIDERAÇÕES FINAIS.....	62
	REFERÊNCIAS	63
	APÊNDICE A – SIGLAS DAS TÉCNICAS	70

1 INTRODUÇÃO

1.1 Motivação e justificativa

Segundo o Censo de 2010 do Instituto Brasileiro de Geografia e Estatística, 13,3 milhões de brasileiros possuem alguma deficiência motora (BRASIL, 2010). Dentre essas, existem pessoas com mobilidade totalmente reduzida, onde não há movimento muscular, ocular e inclusive respiratório; a ausência de comunicação não permite, a utilização de algumas tecnologias assistivas. Uma opção para pessoas com deficiência motora é restaurar a função perdida ou ausente através de um canal de comunicação entre o cérebro e o computador. Essa tecnologia é a Interface Cérebro-Máquina (ICM), que permite transmitir mensagens e comandos à dispositivos externos. Assim, a ICM é um substituto na ausência de nervos e músculos, pois traduz os sinais que antes serviam para realizar uma determinada atividade física em comandos que façam a comunicação com o mundo externo, por meio de hardwares e softwares (WOLPAW et al., 2002). Ou seja, é uma alternativa para melhorar a qualidade de vida ao aumentar a independência do usuário que está acometido por alguma deficiência motora grave (BASHASHATI et al., 2007).

Existem alguns métodos (magnetoencefalografia, tomografia por emissão de pósitrons, ressonância magnética funcional, imagem óptica e a eletroencefalografia) para monitorar a atividade cerebral. A Eletroencefalografia (EEG) é um deles. Através do EEG são adquiridos os sinais neurais, para uso no controle de um dispositivo externo, que funciona sem a requisição da ação muscular, que possui vantagens em relação aos outros métodos por ser mais simples e mais barato (WOLPAW et al., 2002).

Em uma ICM os sinais são adquiridos por meio do EEG com uso de eletrodos (posicionados sobre o couro cabeludo ou intracortical). O sinal é amplificado, digitalizado, pré-processado para extração de características que evidenciem a intenção do usuário (WOLPAW et al., 2002). Para detectar padrões nas intenções do usuário, vários algoritmos de processamento de sinal são empregados, o processamento do sinal é uma das partes mais importante da ICM, pois é ela que possibilita o reconhecimento de padrões. (BASHASHATI et al., 2007). Posteriormente essas características são expressas em comandos para um dispositivo (avatar, neuroprótese ou alguma tecnologia assistiva) (WOLPAW et al., 2002).

A ICM funciona por meio de atividades eletrofisiológicas com diferentes neuromecanismos: atividade sensório-motora, potenciais corticais lentos, P300, potenciais evocados visuais, resposta a tarefas mentais, atividade de células neurais e múltiplos neuromecanismos. (BASHASHATI et al., 2007). A imagética motora é uma atividade mental

sensorio-motora na qual o sujeito imagina realizar determinado movimento motor, sem executá-lo (JEANNEROD, 1995). É uma prática utilizada no controle de próteses mecânicas, computadores (NICOLELIS; BIRBAUMER; MÜLLER, 2004), cadeira de rodas (TANNUS, 2004) e na reabilitação de pacientes com lesões neurológicas, técnica que tem apresentado bons resultados referentes a plasticidade neural e aprendizado motor na reabilitação (BASTOS et al., 2013).

São diversas as técnicas existentes na literatura para o reconhecimento de padrões de imagética motora e controle de uma ICM. Classificar sinais de imagética sem intenção de utiliza-los na ICM, é uma tarefa razoavelmente simples comparada ao uso da ICM. Alterações de humor, disposição física, alimentação e outros fatores internos e externos ao organismo podem influenciar no sucesso do controle da ICM (CABLOCO, 2013).

A hipótese deste trabalho é, portanto, que aplicando diversos métodos computacionais é possível montar um sistema de ICM, para mover um avatar com 4 comandos, utilizando sinais de imagética motora.

2 REVISÃO DE LITERATURA


2.1 Eletroencefalografia e córtex cerebral

O sistema nervoso é responsável por receber mensagens dos órgãos, armazenar informações e coordenar ações. O sistema nervoso central é composto pelo encéfalo que está envolvido pelo crânio e pela medula espinhal que se localiza no interior da coluna vertebral (LINHARES; GEWANDSZNAJDER, 2005).

O encéfalo é constituído pelo cérebro, tálamo, corpo caloso, hipotálamo, cerebelo, hipófise, mesencéfalo, ponte, bulbo e parte da medula espinhal. O cérebro possui dois hemisférios que fazem ligação por meio do corpo caloso; os hemisférios possuem 4 lobos (frontal, parietal, temporal e occipital) (LINHARES; GEWANDSZNAJDER, 2005).

O sistema nervoso possui dois tipos de células específicas, os neurônios e células da glia. Estas últimas são responsáveis pela produção de mielina e fagocitose. Os neurônios por sua vez, recebem e transmitem estímulos nervosos, há cerca de 100 bilhões destes. Os neurônios possuem corpo celular que podem medir até 150 µm, dendritos que recebem o impulso nervoso, e axônios que transmitem os impulsos, ver Figura 1 (LINHARES; GEWANDSZNAJDER, 2005; LOPES, 2004).

Figura 1 – Neurônio



Fonte: Lopes (2004, p.171)

Um impulso nervoso ocorre quando a despolarização se propaga pelo neurônio, pois a membrana em estado de repouso encontra-se polarizada (com carga elétrica positiva externamente a célula e negativa no interior); ao chegar um estímulo na célula ocorre a despolarização e por conseguinte transformação do potencial de repouso em um potencial de ação. Após a passagem do impulso a célula volta ao estado de polarização (LOPES, 2004).

Aumentar o estímulo não aumentará a intensidade do impulso nervoso, pois após atingir o limiar para que ocorra a despolarização o potencial de ação é transmitido ao longo do neurônio; a intensidade das sensações depende da quantidade de neurônios despolarizados e da

frequência dos impulsos. Ademais, a transmissão da informação é mais rápida em células que possuem em volta de seu axônio dobras envoltórias de bainha de mielina (LOPES, 2004).

Na ausência de estímulos externos ainda é possível observar atividade elétrica espontânea dos neurônios. É possível registrar esses potenciais, com amplificadores de alta potência de corrente alternada, pois os sinais adquiridos do córtex cerebral com eletrodos colocados sobre o escalpo são de baixa amplitude e frequência (HOUSSAY, 1980). Berger (1929) realizou o primeiro registro de atividade elétrica de campo do córtex de forma não-invasiva em humano, esse método chama-se eletroencefalografia. Os eletrodos sobre o escalpo capturam sinais da atividade de vários neurônios, porém essa técnica não é permite visualizar os potenciais de ação (HOUSSAY, 1980).

A colocação dos eletrodos é padronizada por uma federação internacional, chamam de sistema 10-20, pois as marcações são baseadas em proporções de 10% e 20% da distância do nasion, inion e pontos pré-auriculares (JASPER, 1958).

O EEG registra apenas as camadas mais superficiais da substância cinzenta cortical. Nelas há poucos corpos celulares. Os registros de EEG podem ser bipolar, quando as flutuações de potencial ocorrem entre dois eletrodos ou unipolar quando a diferença de potencial ocorre entre um eletrodo em um ponto de referência que não está contido no córtex cerebral (GANONG, 1969).

A faixa de frequência dos sinais de EEG é de 0,5 a 100 Hz; sua amplitude é uma variável dependente da frequência (inversamente), do estado de maturação funcional e da localização, possui valores na faixa de 200 μ V. Além desses parâmetros existe a constância das ondas que é uma variável chamada de ritmo, corresponde a uma faixa de frequência quase sempre constante com características específicas, calculando o espectro da potência é possível observar a contribuição das frequências em um instante específico (HOUSSAY, 1980).

Os ritmos observados são:


- Delta (0.5 a 3 Hz): Ondas lentas relacionadas ao estado profundo do sono, com amplitudes pequenas (HOUSSAY, 1980; NYKOPP, 2001)
- Teta (4 a 7 Hz): ondas regulares de grande amplitude (GANONG, 2010). Surgem em alguns indivíduos ao executar tarefas mentais (NYKOPP, 2001).
- Alfa (8,5 a 13 Hz): em estado de vigília, 9 em cada 10 adultos com olhos fechados apresentam esse ritmo (HOUSSAY, 1980). Manifesta-se mais na região posterior (NYKOPP, 2001).

- Beta (18 a 40 Hz): possui amplitude reduzida. Em estado de vigília o ritmo beta substitui o alfa ao abrir os olhos. A supressão desse ritmo e o aparecimento do beta surge ao realizar uma atividade intensa e nova, enquanto o estímulo novo não se torna habitual (HOUSSAY, 1980). Surge também como um harmônico de alfa (GANONG, 2010).
- Gama (30 a 80 Hz): surge quando o sujeito é despertado e mantém a atenção sobre alguma coisa (GANONG, 2010).

Os sinais de EEG não são iguais no mesmo indivíduo em qualquer situação, ele sofre alterações de acordo com a idade (GANONG, 1969). Particularmente, a frequência de alfa sofre alterações em alguns casos, quando há baixo nível de glicose no organismo, baixa temperatura corporal e elevada pressão parcial de CO₂ arterial; essas condições propiciam a sua redução, e em condições inversas seu aumento (GANONG, 2010). Como citado, alfa também desaparece se uma estimulação sensorial, concentração mental, resolução de problemas aritméticos forem realizadas. Esse evento é chamado de dessincronização, é um estado de alerta do sujeito, o alfa é então substituído por uma atividade irregular de baixa voltagem (GANONG, 1969), que Houssay (1980) indica sendo o ritmo beta.

Penfield e Boldrey (1937) criaram homúnculos com representação motora e sensorial do córtex cerebral, ver Figura 2, a área motora está localizada anterior ao sulco central e a área sensorial após o sulco. Quanto maior a complexidade do movimento, maior é a área de representação no córtex, essa representação é, em geral, contralateral (HOUSSAY, 1980).

Figura 2 – Homúnculo motor



Fonte: Houssay (1980, P. 643)

Brodman (1909) mapeia o córtex distinguindo áreas com diferenças estruturais. As áreas referentes ao córtex motor são as 4, 6 e 8 (área motora propriamente dita, área pré-motora e

área motora dos olhos, respectivamente). A área 4, corresponde aos movimentos das articulações de flexão e extensão; a 6 corresponde a rotação da cabeça, olhos e tronco para o lado oposto e flexão ou extensão dos membros contralaterais e a 8 corresponde a área frontal dos olhos (HOUSSAY, 1980).

2.2 Interface cérebro-máquina

A ICM permite a comunicação do usuário com o meio externo por meio do processamento sinal cerebral. Em geral, um sistema de ICM possui os seguintes passos para o seu funcionamento: amplificação do sinal adquirido pelos eletrodos, pois os sinais de EEG possuem amplitude na ordem de microvolts; remoção de artefatos, é aplicada para melhorar a relação sinal-ruído, após esse processamento o sinal ainda continua no domínio do tempo; extração de características e redução da dimensionalidade para facilitar o reconhecimento de padrões; classificação do sinal e controle da interface (MASON; BIRCH, 2003; BASHASHATI et al., 2007).

2.2.1 Atividade sensório-motora

Bashashati et al. (2007) utiliza o termo neuromecanismo para identificar as atividades fisiológicas que são aplicadas em uma ICM. Dentre elas: atividade sensório-motora, potencial cortical lento, P300, potenciais evocados visuais, respostas às tarefas mentais e atividades das células neurais e a combinação de alguns destes.

Eventos cerebrais como o disparo de neurônios cortical específico a ativação sináptica sincronizada e rítmica no córtex sensório-motor que produz um ritmo mu, tem sido utilizado para aplicações em ICM (WOLPAW et al., 2002). A diminuição dos ritmos mu e beta, chamada de Dessincronização Relacionada ao Evento (do inglês *Event-related desynchronization* – ERD), ocorre quando o sujeito se prepara para execução do movimento (PFURTSCHELLER; DA SILVA, 1999b; PFURTSCHELLER, 1999). Após a execução do movimento ocorre a Sincronização Relacionada ao Evento (do inglês *Event-related synchronization* – ERS) dos ritmos mu e beta. (PFURTSCHELLER, 1999). Não é necessário a movimentação real, para que ocorra esses eventos, na imagética motora, eles também ocorrem (PFURTSCHELLER; NEUPER, 1997; MCFARLAND et al., 2000).

Pfurtscheller e Aranibar (1979) realizaram experimentos com a execução de atividades motoras do polegar direito e esquerdo. Registraram eventos com duração de 6s. Os 4s iniciais tratavam-se da preparação para o movimento e 2s posteriores referentes a execução do movimento; sendo os 2s primeiros segundos tomados como referência e o 3º e 4º s como fase

de preparação, em si, para o movimento. Calcularam o ERD durante a execução do movimento dos polegares, e concluíram que houve uma atenuação na potência após o início do movimento. A queda do ERD, ou seja, os valores da redução da potência em alfa, foi significativamente maior na região contralateral que na ipsilateral.

Alomari, Samaha e Alkamha (2013) classificou sinais de tarefas motoras reais utilizando esses eventos como artifício de classificação, obteve um resultado de 97,1% de acurácia. Segundo (WOLPAW et al., 2002) desde meados de 1980, as ICM tem sido implementadas baseadas em ritmos mu/beta.

2.2.2 Métodos de tratamento do sinal

O tratamento do sinal é uma etapa necessária para se obter bons resultados na classificação do sinal. Bashashati et al. (2007), em sua revisão de literatura, cita alguns métodos de extração de características mais utilizados para classificação de sinais utilizando atividade sensorial motora, são eles: Densidade Espectral de Potência (do inglês *Power Spectral Density* – PSD), modelo paramétrico e método de representação tempo-frequência. Além desses, a Transformada Rápida de Fourier (do inglês *Fast Fourier Transform* – FFT), a Transformada Discreta de Wavelet (TDW), as Análises de Componentes Principais (do inglês *Principal Component Analysis* – PCA) também são vistas em trabalhos atuais como técnicas para extrair características dos vetores de eletrodos, PCA também é um método com o objetivo de redução de dimensionalidade.

Movimentos oculares produzem potenciais elétricos, que em um EEG torna-se um artefato, eles se propagam sobre o couro cabeludo e inevitavelmente aparecem no registro do EEG. É possível fazer uma análise visual para remoção de tais artefatos, porém a grande quantidade de dados inviabiliza o método, assim torna-se necessário métodos automáticos que identifiquem e removam sinais de Eletro-oculograma (EOG) (GÓMEZ-HERRERO, 2006).

Métodos de aprimoramento do sinal e filtragem espacial são comumente utilizados como fase de pré-processamento, como filtragem em bandas de frequência específicas, remoção de artefatos fisiológicos, normalização, superfície laplaciana, análise de componentes independentes, padrão espacial comum e referência média comum (BASHASHATI et al., 2007).

2.2.3 Aprendizado de máquina

No mundo real é possível encontrar padrões observando sistemas. Para o computador adquirir essa habilidade é necessário um conjunto de exemplos do processo, que se quer identificar estruturas. O aprendizado de máquina é uma área da inteligência artificial que desenvolve técnicas que podem adquirir o conhecimento, por meio de exemplos do sistema que se quer identificar padrões (REZENDE, 2005).

Existem diversos algoritmos de aprendizado de máquina, cada um tem suas limitações particulares, assim não existe um único algoritmo que apresente a melhor solução para aprendizado de um sistema. A inferência lógica utilizada para isso é a indução, por meio dos exemplos de uma população ela prediz novas amostras, mas para isso os exemplos precisam representar com fidelidade a população (REZENDE, 2005).

O aprendizado pode ser supervisionado quando é dado a máquina de aprendizado a saída prevista para aqueles exemplos, não supervisionado quando a saída não é fornecida, mas objetivo dele é formar agrupamentos com os exemplos fornecidos (REZENDE, 2005) e por reforço quando é oferecido a um agente de aprendizado recompensa ou não da ação realizada (RUSSEL; NORVING, 2004).

O paradigma simbólico é um sistema de aprendizado que aprende por exemplos e contra-exemplos, um dos algoritmos são as árvores de decisão (REZENDE, 2005). As árvores de decisão fazem uma sequência de testes, cada nó de decisão na árvore é um teste de cada um dos atributos, as ramificações ou arestas contém subárvores com os possíveis valores dos testes, até a ramificação final onde o nó folha alcançado corresponde a classe atingida (REZENDE, 2005) (RUSSEL; NORVING, 2004).

No paradigma estatístico as aproximações são teorias probabilísticas, geralmente paramétrica, que mostram como o domínio funciona. (REZENDE, 2005) (RUSSEL; NORVING, 2004). Os sistemas Bayesianos calculam a probabilidade de cada uma das hipóteses, ponderadas pelas probabilidades (RUSSEL; NORVING, 2004).

No paradigma baseado em exemplos a aprendizagem se baseia nas instâncias, a partir dos próprios exemplos conhecidos é possível classificar novos exemplos por meio de similaridade. (REZENDE, 2005) (RUSSEL; NORVING, 2004). Russel e Norving (2004) descrevem o modelo de vizinhos mais próximos, com um dos algoritmos desse paradigma:

A idéia-chave de modelos de vizinhos mais próximo é que as propriedades de qualquer ponto da entrada x específico têm probabilidade de serem semelhantes às propriedades de pontos na vizinhança de x . Por exemplo, se quisermos fazer uma estimativa de densidade – isto é, estimar o valor de uma densidade de probabilidade desconhecida em x – poderemos simplesmente medir a densidade com a qual os pontos são difundidos na vizinhança de x . Isso parece ser muito simples, até

percebermos que precisamos especificar exatamente o que querem dizer por “vizinhança”. Se a vizinhança for muito pequena, ela não conterá quaisquer pontos de dados; se for muito grande, ela poderá incluir todos os pontos de dados, resultando em uma estimativa de densidade que será a mesma em todos os lugares (RUSSEL; NORVING, 2004, p. 711).

O paradigma conexionista descreve unidades conectadas que são inspiradas em modelos biológicos, como as Redes Neurais (REZENDE, 2005). As redes neurais artificiais são baseadas no modelo matemático do neurônio de McCulloch e Pitts (1943).

O neurônio de McCulloch era um dispositivo binário: a sua saída poderia ser pulso ou não pulso, e as suas várias entradas tinham ganho arbitrário e poderiam ser excitatórias ou inibitórias. Para determinar a saída do neurônio, calculava-se a soma ponderada das entradas com os respectivos ganhos como fatores de ponderação, positivos nos casos excitatórios e negativos nos casos inibitórios. Se este resultado fosse maior ou igual a um certo limiar então a saída do neurônio era pulso, e caso contrário era não pulso. Assim, eles implementaram várias funções booleanas usando ganhos iguais a $1/2$ e liminares iguais a 1 (KOVÁCS, 1996, p.22-23).

A capacidade de aprender de uma rede neural está associada a capacidade de adaptar seus parâmetros de forma iterativa (REZENDE, 2005). Elas são compostas de nós e conectadas por vínculos, que possuem peso numérico que descreve a força de conexão, que servem para propagar a ativação. (RUSSEL; NORVING, 2004) (LUGER, 2004). Ela possui propriedades globais como o padrão de conexão entre neurônios e algoritmos de aprendizado como *perceptron*, retropropagação, competitivo e por coincidência hebbiano (LUGER, 2004).

As máquinas de vetores de suporte conseguem representar funções complexas não-lineares, que geralmente são difíceis de treinar com redes neurais, mesmo com muitas camadas (RUSSEL; NORVING, 2004), “devido à abundância de mínimos locais e ao elevado número de dimensões do espaço de pesos” (RUSSEL; NORVING, 2004, p. 725). Elas dividem o espaço em hiperplanos, o hiperplano escolhido é que maximiza a margem dos dados de classes diferentes, realizando assim uma melhor separação entre as classes (ABREU, 2006).

O paradigma Evolutivo possui analogia com a teoria de Darwin, no qual os elementos competem para fazer a classificação. São divididos em algoritmos genéticos, estratégias de evolução e programação genética (REZENDE, 2005).

2.3 Trabalhos relacionados

A dificuldade de distinguir sinais elétricos adquiridos pelo córtex motor por meio de eletrodos advém de fatores externos e internos ao organismo Cabloco (2013), que desafiam a criação de um modelo que seja capaz de discriminar a imagética motora em quaisquer circunstâncias.

Grande parte dos estudos Farias (2014), Tolić e Jović (2013), Alomari, Baniyounes e Awada (2014), Handiru e Prasad (2016), Szczuko (2017), Alomari et al. (2014), Azimirad et

al. (2015), Costa e Oliveira (2012), Vaz e De Melo (2016), Barbosa et al. (2009), Rashid e Ahmad (2016), Pfurtscheller et al. (1997), Azimirad et al. (2015), Huang et al. (2012), Tavella et al. (2010), Lal (2004), Shenoy e Vinod (2014) e Xu e Song (2008) consistem em discriminar duas tarefas da imagética motora ou uma imagética mais o estado parado (sem imagética motora). Dentro desses que fazem discriminação de mais de duas tarefas, existe um subconjunto que aplicam essas técnicas para uso em ICM como os trabalhos Doud et al. (2011), Leeb et al. (2007), Scherer et al. (2008) e Onose et al. (2012).

Alguns trabalhos têm mostrado que os sinais de EEG são únicos para cada pessoa, um exemplo disso é a larga aplicação de uso de sinais da imagética motora e de tarefas mentais para identificação de pessoas (biometria), como nas pesquisas de Yang e Deravi (2012), Khalifa, Roushdy e Salem (2014) e Yang (2013). Além disso, os sinais da imagética é mais particular que os gerados a partir de tarefas reais, no trabalho de Yang e Deravi (2012) eles obtiveram maior precisão ao identificar um sujeito por meio da imagética do que com sinais de EEG de movimentos executados. Em relação a classificação das tarefas, Szczuko (2017) conseguiu mostrar que é mais fácil classificar sinais de movimento motor do que sinais de movimento imaginário. Outro aspecto interessante é que não são necessários muitos eletrodos para obter essa discriminação biométrica, com apenas 1 eletrodo é possível identificar um sujeito que executou alguma tarefa mental ou realizou uma imagética motora com precisão maior de 96%, como no trabalho de Yang e Deravi (2014).

2.3.1 Base EEGMMIB da PhysioNet

A Base de Dados de Movimento/Imagética Motor de EEG (do inglês *EEG Motor Movement/Imagery Dataset* – EEGMMIDB) contém sinais de EEG de movimento e imagética motora (EEGMMIDB, 2009), disponível no site da PhysioNet (GOLDBERGER, 2000), foi coletada pelos desenvolvedores do sistema de instrumentação BCI2000 (SCHALK, 2004), ela contém sinais de movimentos motores e imaginários de membros do corpo humano. São 1526 registros de sinais de EEG com 64 canais, pertencentes a 109 voluntários, com duração de aproximadamente um e dois minutos e adquiridos numa taxa de amostragem de 160 Hz (EEGMMIDB, 2009).

A seguir a descrição de alguns trabalhos que utilizaram a base de dados EEGMMIDB da PhysioNet e realizaram classificação de sinais de imagética motora. Logo após no Quadro 1 há comparação das seguintes características desses trabalhos: classes, sujeitos, eletrodos, método, vetor de característica, classificador e acurácia.

São mencionadas as seguintes siglas para identificar as classes.

- IME – Imagética de Mão Esquerda
- IMD – Imagética de Mão Direita
- IMED – Imagética de Mão Esquerda e Direita
- IPED – Imagética de Pé Esquerdo e Direito
- T0 – Parado (sem movimento ou imagética motora)

Farias (2014) realizou o reconhecimento de duas tarefas da imagética: IME e IMD de 5 sujeitos da base, utilizando como instâncias o sinal bruto de 14 eletrodos (os mesmos utilizados no Emotiv EPOC). Obteve 69 % de acurácia com o método de classificação temporal: Rede Neural Recorrente (do inglês *Recurrent Neural Network* – RNN). Esse tipo de rede possui uma memória dinâmica que utiliza dados de entrada do instante atual e de instantes anteriores, o autor fez uso do algoritmo de rede de estado de eco. Realizou outras classificações utilizando classificadores instantâneos (*Perceptron* de Múltiplas Camadas (do inglês *Multilayer Perceptron* – MLP), Máquinas de Aprendizado Extremo (do inglês *Extreme Learning Machines* – ELM), Máquina de Vetores de Suporte (do inglês *Support Vector Machine* – SVM), porém apresentaram uma taxa de acerto inferior a RNN. Utilizou a validação cruzada *k-fold* e 30 execuções (10 simulações utilizando a validação *3-fold*), porém não descreveu o software utilizado. Apesar da taxa de classificação ter sido 69% com duas classes, esta pesquisa sugere que a utilização de RNN pode trazer resultados melhores (para esse tipo de classificação) em comparação com classificadores instantâneos. Zhang et al. (2017) também utilizou uma RNN para classificação de dados da base da PhysioNet.

Normand e Ferreira (2015) realizam a classificação das 5 atividades (IME, IMD, IMED, IPED e T0) e também das classes referentes aos movimentos executados. Eles chamam de superacorde uma medida instantânea do sinal bruto de todos os canais de EEG. Para eles, cada superacorde é único e pode ser usado para determinar a atividade independente da tarefa executada ou imaginada. Eles fragmentaram as gravações (4.1 ou 4.2s) em trechos chamados de superacordes com tamanhos de: 10, 20, 30, 40, 60, 80, 100, 120, 140 e 160 (que equivalem a intervalo de 0,00625 a 1s de gravação). O classificador utilizado foi uma rede neural com uma camada de entrada (64 eletrodos), duas camadas ocultas com 64 neurônios e a função de ativação do tipo tangente hiperbólica. Utilizaram dados de todos os 109 sujeitos, porém apenas 103 sujeitos seguem o protocolo experimental da base (detalhes na seção 4.3), a inclusão desses 6 sujeitos deixa imprecisa a taxa de acurácia final desse trabalho. Cada conjunto de dados foi dividido em duas partes iguais (randomicamente), uma para treinamento e outra para validação. Com 100 superacordes (0,625s de gravação) a classificação das 5 tarefas de movimento real

chegou a 89,29% de acerto e a classificação das 5 tarefas da imagética motora 88,26%. Esse novo conceito introduzido por Normand e Ferreira (2015), mostrou a necessidade de averiguar o tamanho mínimo da janela que contém a informação necessária para distinguir os movimentos de imagética. Apesar de relatarem que cada superacorde contém uma informação única e que pode definir que tipo de movimento está sendo imaginado, eles observaram que um superacorde de 10 (0.0625 s) apresenta uma taxa de erro maior que um superacorde de 100. Essa informação é útil para aplicação em ICM, pois identificando a menor janela (superacorde) para realizar a classificação dos sinais de forma satisfatória, menor será o tempo de processamento dos dados e mais rápido o sistema de ICM retornará o *feedback* ao usuário.

Alomari (2016) classificou 5 as tarefas (IME, IMD, IMED, IPED e olhos abertos) de 100 sujeitos para aplicação em um controle remoto e duas tarefas basais (olhos abertos e olhos fechados). A metodologia empregada consistiu na escolha de 3 canais (C3, C4 e Cz); filtragem com filtro passa-banda (0,5 a 50 Hz) e remoção de artefatos fisiológicos por meio da ferramenta de Remoção Automática de Artefatos (do inglês *Automatic Artifact Removal – AAR*). Aplicaram TDW da família *Coiflets* (coif1 a coif5), para montar o vetor de característica utilizaram os detalhes cD2 (20 a 40 Hz), cD3 (10 a 20 Hz) e cD4 (5 a 10 Hz), para cada um dos canais. Alguns estimadores de amplitude foram calculados sobre os detalhes: Valor Quadrático Médio (do inglês *Root Mean Square – RMS*), Valor Médio Absoluto (do inglês *Mean Absolute Value – MAV*), Integral do EEG (do inglês *Integrated EEG – IEEG*), Integral Quadrática Simples (do inglês *Simple Square Integral – SSI*), Variância do EEG (do inglês *Variance of EEG – VAR*), Mudança de Amplitude Média (do inglês *Average Amplitude Change – AAC*). Foram 30 configurações distintas: 6 estimadores de amplitude e 5 famílias wavelets. Cada configuração possui 9 vetores de características (3 canais e 3 detalhes). Para realizar a classificação desses dados aplicaram o classificador SVM que fazia distinção entre olhos fechados e abertos e uma rede neural que realizava a classificação referente a imagética motora: olhos abertos, IME, IMD, IMED e IPED. A aplicação no sistema teria a seguinte função: fechar olhos (botão ligar e desligar); IME e IMD (mudar o canal para a frente e para trás) e IMED e IPED (aumento e diminuição de volume). A melhor configuração para SVM foi com gama = 7 e grau = 5 e coif3 e características MAV, apresentando 72,04% de precisão. A rede neural com 13 camadas ocultas, usando coif2 e o recurso IEEG apresentou uma acurácia de 70,62%. No treinamento foi utilizado 80% dos dados e no teste 20%, executado 20 vezes com dados randomizados. A taxa de acerto de 70,62% para 5 classes é alta comparada a outros trabalhos, como o de Tolić e Jović (2013) com os mesmos eletrodos conseguiram 68,21 % na classificação de IME e IMD.

Tolić e Jović (2013) realizaram a classificação de sinais IME e IMD, selecionaram 4 sujeitos (S001, S003, S005 e S007) da base, analisando apenas 3 canais (C3, C4 e Cz). Calcularam TDW família *Daubechies* (db4) e realizaram a decomposição do sinal em 5 detalhes e 1 aproximação calculando também a energia para cada decomposição, montando assim um vetor de característica com 18 entradas (3 canais com 6 características da TDW). Para a classificação usaram a rede neural do tipo *feedforward* com uma camada oculta e com função de ativação sigmoide. O número de neurônios utilizados variou de 5 a 60. No treinamento foi utilizado 70% dos dados, na validação 10% e no teste 20%, executado 20 vezes. Obtiveram acurácia de 68,21%, com a seguinte configuração: 20 neurônios na camada oculta e função de aprendizagem do tipo *backpropagation* resiliente. Assim, dentre os trabalhos que utilizaram essa base aqui descritos, este apresentou a segunda menor taxa de acurácia, depois do trabalho de Handiru e Prasad (2016) que também realizaram a classificação de tarefas IME e IMD com 16 eletrodos.

Alomari, Baniyounes e Awada (2014) classificaram sinais de 20 sujeitos de IME e IMD, utilizando apenas os canais C3, C4 e Cz. Aplicaram um filtro passa-banda de 0,5 a 50 Hz pela caixa interativa do Matlab EEGLAB e removeram artefatos de olhos e músculos pelo EEGLAB (AAR). Calcularam TDW da família *Daubechies* (db1 a db10), decompondo em 4 detalhes e 1 aproximação, mas utilizaram apenas o segundo (20 a 40 Hz) e terceiro detalhe (10 a 20 Hz), por fornecerem informações dos ritmos mu e beta. Calcularam o RMS e MAV, formando 12 vetores de características. Os classificadores usados foram o SVM e rede neural. No SVM, o grau e gama variaram de 1 a 10 e o número de camadas ocultas para a rede neural foi 1 a 10. No treinamento foi utilizado 80 % dos dados e no teste 20 %, este processo foi repetido 10 vezes com os dados randomizados. A maior acurácia apresentada foi de 84,5 % com o classificador SVM (grau=7 e gama=3), com a família wavelet db8. Esse trabalho teve um melhor desempenho comparado ao trabalho de Tolić e Jović (2013), ambos utilizaram os mesmos canais, mesmas classes e decomposição da TDW em *Daubechies*. A diferença de acurácia ficou em torno de 16%, indicando que essa discrepância pode ser justificada pelo uso de filtros passa-banda e pela remoção de artefatos de EOG e muscular (Eletromiografia – EMG).

Zhang et al. (2017) realizaram a classificação de 5 tarefas: IME, IMD, IMED, IPED e olhos abertos, utilizando 64 eletrodos. A metodologia é baseada no aprendizado profundo, utilizando uma arquitetura de rede neural específica denominada Memória Longa de Curto Prazo (do inglês *Long Short-Term Memory* – LSTM) é que é uma arquitetura de RNN. O modelo LSTM é usado sem realizar pré-processamento, normalização, suavização, análise ou

extração de características. O modelo de aprendizagem profunda em LSTM construído possui 7 camadas. O modelo tem: 1 camada de entrada, 2 camadas ocultas (LSTM dinâmicas, 7 camadas RNN) e 1 camada de saída. Esse método foi testado em 1 sujeito obtendo acurácia de 95,05%. 75% dos dados são usados para treinamento e 25% para teste. Implementaram o mesmo método em 20 outros sujeitos escolhidos aleatoriamente e acurácia ficou em torno de 90 a 99,4%. O tipo de arquitetura escolhida por Zhang et al. (2017), pode justificar o êxito nesse trabalho além do emprego dos 64 eletrodos, visto que Farias (2014) também utilizou RNN e com 3 eletrodos, obteve apenas 69% de acurácia.

Handiru e Prasad (2016) classificam sinais de IME e IMD de 85 sujeitos. O objetivo do foi escolher o melhor conjunto de canais de EEG que apresentem a melhor acurácia na classificação. Eles propõem o método de otimização multiobjetiva iterativa para seleção de canais, para escolher o melhor conjunto de canais de EEG, além de avaliarem a eficiência de outros métodos. No pré-processamento os dados são filtrados com um filtro passa-banda de 4 a 40 Hz; foi realizada correção da linha de base, subtraindo a média das amplitudes de sinal obtidas durante os ensaios, quando os olhos foram mantidos abertos. Foi realizada a seleção dos canais pelo método proposto; calculado um ranking de todos os canais com base em pesos. Para extração de características é utilizado Padrão espacial comum do banco de filtros modificado e para seleção de características o algoritmo de Máxima relevância e mínima redundância. A classificação foi feita com SVM (libSVM), utilizando validação cruzada (5-fold). Com 16 eletrodos obtiveram uma acurácia de 63%. O método de seleção de canais proposto por eles, não obteve êxito comparado aos trabalhos de Farias (2014), Tolić e Jović (2013), Alomari, Baniyounes e Awada (2014) e Azimirad et al. (2015) que realizaram o mesmo tipo de classificação (IME e IMD) obtendo acurácia superior e utilizando uma quantidade de eletrodos inferior a 16.

Szczuko (2017) classificou dados de 106 sujeitos utilizando 21 canais (FC5, FC3, FC1, FCz, FC2, FC3, FC6, C5, C3, C1, Cz, C2, C3, C6, CP5, CP3, CP1, CPz, CP2, CP3 e CP6). O conjunto de dados foi pré-processado no *software Brainstorm*, fazendo a segmentação em 5 bandas de frequência (delta, teta, alfa, beta e gama). Foram extraídas características sobre as 5 bandas de frequência: soma do quadrado das amostras, média, variância, valor mínimo e máximo para cada um dos 21 eletrodos. Para 9 pares de eletrodos posicionados simetricamente (por exemplo C1 e C2) foi calculada a diferença entre eles. Criaram 6 cenários possíveis de classificação para movimento real e 6 para imaginário. Os cenários de classificação de imagética motora eram os seguintes: *Ball* (IME, IMD e T0), *Dall* (IMED, IPED e T0), *Bmotion* (IME+IMD de T0), *Dmotion* (IMED+IPED de T0), BLR (IME e IMD) e DUD (IMED e IPED);

o mesmo foi feito para os sinais de movimento real. A classificação é feita com *Rough Sets*. A melhor acurácia apresentada foi do conjunto BRL (IME e IMD) com 88%. Esse trabalho mostra, que a classificação de mais de duas tarefas da imagética motora é desafiadora, o esforço em classificar 3 tarefas diferentes da imagética motora mostrou valores inferiores comparado à acurácia apresentada na classificação da imagética de membros contralaterais.

Alomari et al. (2014) fizeram a classificação de tarefas IMED e IPED de 100 sujeitos utilizaram apenas os canais C3, C4 e Cz. Realizaram a filtragem por meio do EEGLAB com um filtro passa-banda (0,5 a 50 Hz), posteriormente removeram artefatos de EOG e EMG com AAR do EEGLAB. Calcularam a TDW da família *Daubechies* (db2 a db20, índices pares), *Symlets* (sym2 a sym20, índices pares) e *Coiflets* (coif1 a coif5). Os sinais foram decompostos em coeficientes, 4 detalhes e 1 aproximação, mas para aplicação utilizaram 3 detalhes: cD2 (20 a 40 Hz), cD3 (10 a 20 Hz) e cD4 (5 a 10 Hz). Calcularam sobre os coeficientes 6 estimadores matemáticos (MAV, RMS, AAC, IEEG, SSI, VAR). Assim, foram analisadas 6 configurações para cada um dos estimadores matemáticos, cada configuração com dimensão 9 (3 canais e 3 detalhes). O classificador utilizado é uma rede neural (*backpropagation*), o número de camadas ocultas variou de 1 a 20. No treinamento foi utilizado 80% dos dados e no teste 20%, executado 10 vezes de forma randômica. O melhor desempenho alcançou 89,11% utilizando 20 camadas ocultas, com uso do MAV e família coif4. Este trabalho apresentou o melhor desempenho, dentre estes aqui descritos na classificação da imagética para tarefas de IME e IMD; fazendo uso de apenas 3 eletrodos.

Azimirad et al. (2015) realizam a classificação de IME e IMD, utilizando os canais C3 e C4, selecionam 70 sujeitos escolhidos aleatoriamente. Realizaram a decomposição da TDW, família *Daubechies*, decompondo o sinal e utilizando os coeficientes cD2 (20 a 40 Hz), cD3 (10 a 20 Hz) e calculando a potência para cada coeficiente. O classificador utilizado é uma rede neural que faz uso de algoritmos de otimização para o cálculo de seus parâmetros, a função de ativação utilizada é Morlet. A melhor acurácia apresentada foi utilizando a rede neural baseada em Otimização por enxame de partículas, de 5ª ordem e utilizando cD2 como entrada, o valor foi de 89% acerto. Mostraram que é possível obter resultados semelhantes ao trabalho de Alomari et al. (2014), por meio de algoritmos de otimização para o cálculo dos parâmetros da rede neural, com apenas 2 eletrodos e sem utilizar remoção de artefatos.

Quadro 1 – Comparação dos trabalhos que utilizaram a base EEGMMIB da PhysioNet

(Continua)

Autor	Classes	Sujeitos	Eletrodos	Método	Vetor de característica	Classificador	Acurácia
Farias (2014)	IME e IMD	5: S001, S023, S034, S058 e S077	14: AF3, AF4, F3, F4, F7, F8, FC5, FC6, P7, P8, T7, T8, O1 e O2.	Sinal original (bruto)	14: eletrodos	RNN	69 %
Normand e Ferreira (2015)	IME, IMD, IMED, IPED e T0	109	Todos	Sinal original (bruto)	64: eletrodos	Rede neural: 2 camadas ocultas com 64 neurônios.	88,26 %
Alomari (2016)	IME, IMD, IMED, IPED e olhos abertos	100	3: C3, C4 e Cz	I: Filtro passa-banda II: Remoção de AAR III: TDW (coif2) IV: Decomposição (cD2, cD3 e cD4) IV: Cálculo do IEEG	9: 3 canais e 3 detalhes para cada canal	Rede neural: 13 camadas ocultas.	70,62 %
Tolić e Jović (2013)	IME e IMD	4: S001, S003, S005 e S007	3: C3, C4 e Cz	I: TDW (db4) II: Decomposição (5 detalhes e 1 aproximação) III: Cálculo da energia	18: 3 canais e 6 decomposições (5 detalhes e 1 aproximação) para cada canal	Rede neural: 1 camada oculta, 20 neurônios, função de ativação sigmoide.	68,21 %

(Continuação)

Autor	Classes	Sujeitos	Eletrodos	Método	Vetor de característica	Classificador	Acurácia
Alomari, Baniyounes e Awada (2014)	IME e IMD	20	3: C3, C4 e Cz	I: Filtro passa-banda II: Remoção de EOG e EMG III: TDW (db8) IV: Decomposição (cD2 e cD3) IV: Cálculo do RMS e MAV	12: 3 canais, 2 detalhes para cada canal e 2 estimadores de amplitude.	SVM	84,5 %
Zhang et al. (2017)	IME, IMD, IMED, IPED e olhos abertos	1: S001	64	Sinal original (bruto)	64: eletrodos	RNN e LSTM	95,05 %
Handiru e Prasad (2016)	IME e IMD	85	16	I: Correção da linha de base II: Filtro passa-banda (4 a 40 Hz) III: Seleção do canal IV: Extração de características (filtro espacial) V: Seleção de características (redução)	Menor que 36 (9 bandas de frequência, 2 filtros espaciais e 2 classes): Reduzido por meio de máxima relevância e mínima redundância	SVM: LibSVM	63 %

(Conclusão)

Autor	Classes	Sujeitos	Eletrodos	Método	Vetor de característica	Classificador	Acurácia
Szczuko (2017)	IME e IMD	106	21: FC5, FC3, FC1, FCz, FC2, FC3, FC6, C5, C3, C1, Cz, C2, C3, C6, CP5, CP3, CP1, CPz, CP2, CP3 e CP6.	I: 5 bandas de frequência II: Cálculo das características	615: 5 bandas, 5 características em 21 eletrodos, 1 característica em 9 pares de eletrodos	Rough Sets	88 %
Alomari et al. (2014)	IMED e IPED	100	3: C3, C4 e Cz	I: Filtro passa-banda II: Remoção EOG e EMG III: TDW (coif4) IV: Decomposição (detalhes cD2, cD3 e cD4) V: Cálculo de MAV	9: 3 canais e 3 detalhes para cada canal	Rede neural: 20 camadas ocultas.	89,11 %
Azimirad et al. (2015)	IME e IMD	70	2: C3 e C4	I: TDW (db) II: Decomposição cD2 III: Potência	4: 2 canais, 1 detalhe e 1 característica.	Rede neural (Otimização por enxame de partículas)	89 %

Fonte: Farias (2014), Normand e Ferreira (2015), Alomari (2016), Tolić e Jović (2013), Alomari, Baniyounes e Awada (2014), Zhang et al. (2017), Handiru e Prasad (2016), Szczuko (2017), Alomari et al. (2014) e Azimirad et al. (2015).

Observando o Quadro 1, apenas 3 trabalhos realizaram a classificação com mais de 2 classes e os que obtiveram melhor desempenho fizeram uso dos 64 eletrodos disponíveis, alcançando 95,05% de acurácia em Zhang et al. (2017). Porém, este aplicou a técnica em apenas 1 sujeito da base. A classificação binária utilizou entre 2 a 21 eletrodos atingindo 89,11% em Alomari et al. (2014) que realizou a decomposição do sinal no tempo e na frequência com a TDW. Os tratamentos aplicados no sinal foram desde a sua utilização em estado bruto, decomposição em TDW, remoção de artefatos, filtragem com filtro passa-banda, seleção canais, redução da dimensionalidade entre outros. Não havendo, aparentemente, um método mais adequado para classificação. Nota-se na classificação binária a presença dos eletrodos C3, Cz e C4, escolha justificada por estarem localizados sobre a área motora e representarem os membros analisados como visto no homúnculo de Penfield e Boldrey (1937).

2.3.2 BCI Competition

BCI *Competition* é uma competição que avalia processamento de sinais de métodos de classificação de sinais de ICM, ela se encontra no seu quarto torneio. As duas últimas competições possuíram categorias para classificação sinais de imagética motora, sendo aqui detalhada a III competição (conjunto de dados IIIa) e a IV competição (conjunto de dados IIa); que envolvem a imagética de 4 classes (mão direita, esquerda, pés e língua). Os dados são disponibilizados para os participantes, em duas partes: uma com os rótulos das classes para aplicarem os métodos de processamento do sinal e treinar o classificador e outra com um arquivo sem rótulo para avaliar o método. Neste último, os participantes devem inferir a classe para cada exemplo. O vencedor é aquele que alcançar o maior índice *kappa* médio de todos os sujeitos dos dados fornecidos (BLANKERTZ et al., 2006; BCI COMPETITION III, 2005; TANGERMANN et al., 2012; BCI COMPETITION IV, 2008).

No BCI *Competition* III a aquisição de dados foi realizada com uma taxa de amostragem de 250 Hz e com 60 eletrodos (EEG de 64 canais da Neuroscan). Os sujeitos foram instruídos a imaginar o movimento ao visualizarem a instrução gráfica no monitor. Foram coletados dados de 3 sujeitos que realizaram pelo menos 6 coletas cada um deles. Cada coleta continha 10 exemplos de cada classe, dispostos aleatoriamente, com duração de 4s cada exemplo (BLANKERTZ et al., 2006).

No BCI *Competition* IV a aquisição de dados foi realizada com uma taxa de amostragem de 250 Hz e com 22 eletrodos e mais 3 eletrodos dedicados a aquisição de EOG. Os sujeitos foram instruídos a imaginar o movimento ao visualizarem a instrução gráfica no monitor. Foram

coletados dados de 9 sujeitos que realizaram 6 coletas cada um deles. Cada coleta continha 12 exemplos de cada classe, com duração de 3s cada exemplo. Antes de iniciar a aquisição da imagética foi coletado durante 5min um protocolo para estimar a influência do EOG (TANGERMANN et al., 2012).

Os competidores disponibilizam uma síntese dos métodos empregados que está disponível em BCI *Competition* III - Resultados IIIa (2005) e BCI *Competition* IV - Resultados IIa (2008). Alguns dos pré-processamentos empregados foram: superfície laplaciana, filtro passa-banda, ICA, remoção de artefatos, remoção de EOG, Padrões Espaciais Comuns (do inglês *Common Spatial Patterns* – CSP), seleção de eletrodos e *downsampling*. No tratamento do sinal foram aplicados métodos de seleção de eletrodos por meio do índice de *fisher*, uso de CSP, cálculo do espectro da amplitude e uso logaritmo da variância. E os classificadores apresentados foram: SVM, K Vizinhos Mais Próximos (do inglês *K-Nearest Neighbor* – KNN), Análise de Discriminante Lineares (do inglês *Linear Discriminant Analysis* – LDA), Bagging, Naive Bayes e Ensemble. (BCI COMPETITION III - RESULTADOS IIIA, 2005; BCI COMPETITION IV - RESULTADOS IIA, 2008).

Na Tabela 1 há o valor do *kappa* médio e dos desvio-padrão para cada um dos competidores.

Tabela 1 – Resultados do BCI *Competition*

BCI <i>Competition</i>	Competidores	<i>Kappa</i> médio	Desvio
III-IIIa (3 sujeitos)	Guan, Zhang e Li	0,79	0,04
	Gao, Wu e Wei	0,69	0,24
	Hill e Schröder	0,63	0,29
IV-IIa (9 sujeitos)	Ang et al.	0,57	0,18
	Guangquan, Gan e Xiangyang	0,52	0,23
	Song, Wu e Zhang	0,31	0,15
	Coyle, Satti e McGinnity	0,30	0,20
	Wu et al.	0,29	0,13

Fonte: Blankertz et al. (2006), BCI *Competition* III - Resultados IIIA (2005), Tangermann et al. (2012) e BCI *Competition* IV - Resultados IIA (2008).

3 OBJETIVOS

3.1 Gerais

Investigar métodos que permitam a criação de uma interface cérebro-máquina capaz de reconhecer 3 imagéticas motoras mais o estado de repouso, em tempo real, para mover um avatar em ambiente gráfico.

3.2 Específicos

- Avaliar a capacidade de classificar sinais de EEG sem extração atributos, de forma *off-line* com sinais de uma base de dados da PhysioNet.
- Implementar técnicas de pré-processamento, extração de atributos e redução de dimensionalidade, bem como comparar seus desempenhos de forma *off-line* e *online*.
- Comparar o desempenho das arquiteturas de classificadores nas técnicas implementadas.
- Identificar o (os) método (s) mais adequado (s) para projetar uma ICM para a amostra avaliada.

4 METODOLOGIA

4.1 Descrição dos experimentos

Foram realizados experimentos com sinais de imagética motora, com sinais de uma base de dados e com dados coletados em 4 indivíduos. Os experimentos com a base contemplaram 4 estados de imagéticas motoras mais o estado parado: IME, IMD, IMED, IPED e T0; os experimentos com os sinais coletados foram com as classes: IME, IMD, IPED e T0.

Os experimentos realizados com a base de dados tiveram o objetivo de discriminar tarefas da imagética motora, sem o intuito de implementação com ICM. Tendo como foco a compreensão do comportamento do sinal no seu estado bruto, a redução a quantidade de eletrodos, o comportamento do sinal após uso de um filtro passa-banda em um ritmo específico e criação um modelo generalista com dados de vários sujeitos.

Os dados coletados foram processados com a finalidade do uso em ICM. E foram aplicados em dois tipos de metodologias: *off-line* e *online*. A metodologia do tipo *off-line* foi realizada com 2 coletas de cada sujeito adquiridas conforme o protocolo experimental descrito posteriormente, sendo a primeira coleta utilizada no treinamento do classificador e a segunda na predição – para avaliar a capacidade de generalização do modelo criado com a chegada de novos dados. Sendo assim, um experimento *pseudo-online*, pois não se caracteriza somente pelo desempenho do classificador dentro do universo de treinamento, validação e teste. Porém, também não se trata de um experimento *online*, uma vez que a coleta de predição não foi adquirida com o uso do avatar. A metodologia *online* foi realizada com 6 coletas adquiridas pelo protocolo experimental de aquisição de dados *off-line* de cada indivíduo para geração do modelo e 1 a coleta *online*, na qual os dados foram gravados durante a aplicação do avatar.


4.2 Experimentos com a base EEGMMIDB

Os sinais de EEG da base de dados *EEGMMIDB* foram registrados com 64 eletrodos. Os eletrodos foram dispostos de acordo com o Sistema Internacional 10-10 (baseado no sistema 10-20 de Jasper (1958)) que inclui eletrodos adicionais de acordo com as Diretrizes da sociedade americana de eletroencefalografia para a nomenclatura padrão da posição do eletrodo (NOMENCLATURE, 1991), excluindo os eletrodos Nz, F9, F10, FT9, FT10, A1, A2, TP9, TP10, P9, P10 (EEGMMIDB, 2009).

Na Figura 3 há os 64 canais (FC5, FC3, FC1, FCz, FC2, FC4, FC6, C5, C3, C1, Cz, C2, C4, C6, CP5, CP3, CP1, CPz, CP2, CP4, CP6, FP1, FPz, FP2, AF7, AF3, AFz, AF4, AF8, F7, F5, F3, F1, Fz, F2, F4, F6, F8, FT7, FT8, T7, T8, T9, T10, TP7, TP8, P7, P5, P3, P1, Pz, P2,

P4, P6, P8, PO7, PO3, POz, PO4, PO8, O1, Oz, O2 e Iz) e inscritos na área azul 15 canais (FC3, FC1, FCz, FC2, FC4, C3, C1, Cz, C2, C4, CP3, CP1, CPz, CP2 e CP4) que também foram objetos de estudo no presente trabalho, por estarem localizados sobre a área motora.

Figura 3 – 64 Canais de EEG



Fonte: EEGMMIDB (2009) (adaptado)

Cada indivíduo realizou 14 experimentos, sendo eles basais, de movimento motor real e imaginário. O protocolo do experimento foi feito da seguinte forma: Um alvo foi exibido no lado esquerdo, direito, superior ou inferior da tela e o sujeito devia abrir e fechar ou imaginar abrir e fechar o membro correspondente (punho esquerdo ou direito, ambos os punhos ou ambos os pés) até que o alvo desaparecesse. E em seguida o voluntário relaxaria (EEGMMIDB, 2009).

As gravações foram realizadas com corridas de 4,1 ou 4,2 s, possuindo assim 656 ou 672 amostras, respectivamente (EEGMMIDB, 2009). A gravação com tamanho de 4,2 s só foi encontrada nos sujeitos S001, S003, S007, S021 e S022 (dentro do nosso espaço amostral de S001 à S030) e apenas na tarefa referente ao descanso.

Dos 109 voluntários disponíveis no banco, foi observado que 6 sujeitos (S088, S089, S092, S100, S104 e S106) apresentaram diferenças na frequência de amostragem, tempo de gravação ou não seguiam o protocolo de tarefas a serem executadas.

Foram selecionados 3000 exemplos (gravações de 4,1 ou 4,2 s), 100 exemplos de cada sujeito, distribuídos entre as classes IME, IMD, IMED, IPED e T0. Nas classes IME, IMD, IMED e IPED foram selecionados os 20 primeiros exemplos e para classe T0 foram escolhidos randomicamente 20 exemplos.


Filtragem no ritmo mu

Através das medições contínuas de EEG e monitoramento das ondas alfa é possível controlar um computador com determinado esforço mental controlando a amplitude dessas ondas. O ritmo mu está associado a atividade motoras e é registrado no córtex motor, estando na mesma faixa do ritmo alfa, porém esse se encontra sobre o córtex occipital. Sua amplitude diminui com o movimento ou intenção de movimento (OCHOA, 2002).

Aqui, foi selecionada a faixa de frequência correspondente ao ritmo mu, em todas as tarefas da imagética motora dos 30 sujeitos analisados. Para isso, foi aplicado um filtro passa-banda de 7 a 13 Hz, por meio da caixa iterativa do toolbox do EEGLAB para Matlab (DELORME; MAKEIG, 2004).

A filtragem foi realizada para cada sujeito e cada tarefa da imagética. A Figura 4, a seguir, exibe a caixa iterativa do EEGLAB, os dados como frequência de amostragem (*Data sampling rate*) teve um valor fixo de 160 Hz para todos os dados, quantidade de pontos por exemplo (*time points per epoch*) teve um valor variável 656 ou 672 dependendo do sujeito e tarefa e o número de canais (*Number of channels*) que corresponde ao número de eletrodos analisados 15 e 64 (foi feita a filtragem para essas duas configurações).

Figura 4 – Caixa iterativa do EEGLAB para filtragem



Fonte: Print screen do EEGLAB

Classificação dos sinais

O aprendizado de máquina é uma área da Inteligência Artificial capaz de construir sistemas que podem adquirir conhecimento de forma automática. Um sistema baseado em aprendizado de máquina toma decisões baseado em exemplos de problemas anteriores. Existem


muitos algoritmos que realizam esse tipo de tarefa e o desempenho deles depende de cada aplicação (REZENDE, 2003).

Foi aplicado a classificação como método de aprendizado supervisionado, que obtém conclusões a partir de exemplos com suas respectivas respostas desejadas (classes). Os classificadores utilizados possuem paradigma conexionista, modelos que são inspirados no modelo biológico (como o MLP) (PARENTE, 2012).

A classificação do sinal foi realizada de forma individual, para cada um dos 30 sujeitos, e em conjunto unindo 10 corridas de cada um dos sujeitos, sendo assim 60 corridas de cada classe. Em experimentos individuais cada sujeito possuiu um classificador, e em experimentos em conjunto havia apenas um classificador com parte dos sinais dos 30 sujeitos.

Para o treinamento e teste das máquinas de aprendizado, foi utilizado o software de mineração de dados Weka (HALL, 2009), na versão 3.8.0. Weka é um software de mineração de dados que contém algoritmo de aprendizagem de máquina, ele traz ferramenta de *Preprocess*, *Classify*, *Cluster*, *Associate*, *Select attributes* e *Visualize* em sua interface, ver Figura 5 (HALL, 2009).

Figura 5 – Weka



Fonte: Print screen do Weka

Assim, foram realizadas 60 classificações de forma individual, com 64 eletrodos com dados brutos; 60 classificações de forma individual, com 15 eletrodos com dados brutos; 60 classificações de forma individual, com 64 eletrodos com dados filtrados em ritmo mu; 60 classificações de forma individual, com 15 eletrodos com dados filtrados em ritmo mu; 4 classificações em conjunto (64 eletrodos com dados brutos, 15 eletrodos com dados brutos, 64 eletrodos com dados filtrados e 15 eletrodos com dados filtrados). O classificador utilizado foi o MLP, os parâmetros do classificador no Weka estão descritos no Quadro 2.

Quadro 2 – Parâmetro das configurações do classificador no *software* Weka

Classificador	Parâmetro do software
MLP	GUI: False, autoBuild: True, batchSize: 100, debug: False, doNotCheckCapabilities: False, hiddenLayers: 20, learningRate: 0.3, momentum: 0.2, nominalToBinaryFilter: True, normalizeAttributes: True, normalizeNumericClass: True, numDecimalPlaces: 2, reset: True, seed: 0, trainingTime: 500, validationSetSiz: 0 e validationThreshold: 20. Percentage split: 66% Versão: Weka 3.8.0

Fonte: Weka 3.8.0

4.3 Experimentos com dados coletados

Este trabalho fez uso da aprovação CAAE: 80352217.5.1001.5208. Foi realizado um estudo do tipo explicativo de abordagem quantitativa. No qual o tamanho da amostra foi de quatro sujeitos. E os critérios de elegibilidade de inclusão são: voluntários com ou sem deficiência motora; exclusão: voluntários acometidos por algum distúrbio neurológico.

4.3.1 Protocolo dos experimentos

A aquisição do sinal foi realizada no Parque Tecnológico de Eletroeletrônicos e Tecnologias Associadas de Pernambuco, Recife/PE, com uso dos equipamentos e a cooperação da equipe Neurobots (NEUROBOTS, 2017) na coleta de dados.

O EEG utilizado na coleta de dados possui 14 canais. Originalmente é o EMOTIV EPOC + (EMOTIV, 2017) que foi readaptado para que seus canais estivessem posicionados na área motora.

Os canais foram projetados sobre uma touca, os eletrodos contemplados foram os seguintes: FC3, FC1, FCz, FC2, FC4, C3, C1, Cz, C2, C4, CP3, CP1, CP2 e CP4. Os mesmos eletrodos utilizados na análise da base de dados, anteriormente, com exceção do CPz. Além do terra em AFz e a referência no processo mastoide esquerdo.


A seguir algumas especificações técnicas do equipamento, disponível em Emotiv (2017):

- Taxa de amostragem: 128 ou 256 Hz (2048 interno)
- Largura de banda: 0.2 a 43 Hz (filtros notch de 50 Hz e 60 Hz)
- Resolução: 14 bit ou 16 bit por canal
- Resolução LSB: 0.51 μ V @ 14 bit / 0.13 μ V @ 16 bit
- Faixa dinâmica: $\pm$ 4.17 mV

O sistema de captura utilizado fez uso do: Emotiv Epoc + acoplado na touca; gel condutivo de EEG; e os softwares Emotiv Epoc e Matlab.

Na Figura 6 há o sinal bruto adquirido com o EEG Emotiv.

Figura 6 – Exemplo da saída da aquisição de 1s do sinal bruto



Fonte: Autora

Cada coleta teve duração de 6 min sem pausas, entretanto entre as coletas foi facultada pausas de 5 a 10 min para descanso. Uma coleta foi composta por 10 eventos de cada classe, cada uma com duração de 5s que foi intercalada com a instrução de “Atenção” com duração de 4s. A Figura 7 exhibe a ordem das instruções de uma coleta.

Figura 7 – Protocolo de coleta


Imagética		T0		IME		IMD		IPED
Instrução	Atenção	Relaxado	Atenção	Esquerda	Atenção	Direita	Atenção	Pé
Duração	4s	5s	4s	5s	4s	5s	4s	5s

10 vezes

Fonte: Autora


O sistema de coleta de dados brutos pertence a Neurobots, foi adaptado para essa aplicação com 4 classes. Ele foi desenvolvido no software Matlab, *app-designer*, o *layout* com a tela de instrução para o usuário está na Figura 8. O aplicativo exhibe as seguintes mensagens: Atenção, relaxar, esquerda, direita e pé.

Figura 8 – Aplicativo de coleta de dados



Fonte: *Print screen* do aplicativo de coleta de dados adaptado da Neurobots

Terminada a coleta de dados, foram aplicados os métodos de tratamento do sinal e o treinamento do classificador. Com o modelo pronto, o usuário utilizou a interface gráfica do *avatar*, uma adaptação do sistema de coletas. Nela há um gráfico representando um humano com membros destacados na cor vermelha, ver Figura 9.

Figura 9 – Aplicativo do *avatar*

Fonte: Autora

Na tela foi feita a seleção do sujeito que fazia uso do sistema, esta seleção carregou o modelo do classificador treinado e as funções que fizeram o tratamento no sinal bruto adquirido pelo EEG. Além de exibir a acurácia de treinamento e teste para visualização do desempenho atingido *off-line*.


Ao iniciar, foi exibida uma instrução de “Atenção” e logo depois a instrução “Imaginar”, na qual o sujeito foi convidado a imaginar uma das 3 classes (IME, IMD e IPED) ou a manter-se relaxado (T0). “Imaginar” teve duração de 5s, passado esse tempo, esses sinais foram

processados em tempo real, conforme o método escolhido, gerando um *label* referente a uma das classes.

Após o processamento do sinal adquirido, foi exibida a mensagem “Avatar”, para que o usuário visualizasse no gráfico a predição do sistema. Assim, o gráfico exibiu uma das 4 classes: movendo (caso IME, IMD ou IPED) caso imagética ou permanecendo parado (caso T0).

A Figura 10 exibe as saídas possíveis para cada classe, sendo um *feedback* visual da resposta do sistema sobre a intenção do usuário.


Figura 10 – Avatar



Fonte: Autora

A Figura 11 exibe o usuário movendo o avatar em tempo real com o sistema de ICM.

Figura 11 – Aplicação *online*



Fonte: Autora

O protocolo *online* foi dividido em 4 corridas, uma para cada classe, mostrada na Figura 12. Após cada corrida os dados foram gravados para futuras análises com os métodos de tratamento do sinal.

Figura 12 – Protocolo do avatar

Instrução	Atenção	Imaginar	Avatar
Duração	4s	5s	1s

10 vezes

Fonte: Autora

Foram realizadas coletas em 4 sujeitos. Os sujeitos S1, S2 e S3 são do sexo masculino e sujeito 4 do sexo feminino, com idade entre 24 e 26 anos. O S1 possui tetraplegia com lesão medular incompleta, os demais são saudáveis ao nível de deficiência motora.

O Quadro 3 contém quantidade de coletas realizadas pelos usuários e a distribuição de acordo com o tipo de experimento (*off-line* e *online*).

Quadro 3 – Distribuição das coletas


Sujeito	Total		Utilizadas nos experimentos <i>Off-line</i>	Utilizadas nos experimentos <i>Online</i>	
	<i>Off-line</i>	<i>Online</i>		<i>Off-line</i>	<i>Online</i>
S1	6	1	1ª e 2ª coletas	1ª a 6ª	1ª
S2	25	2	1ª e 2ª coletas	20ª a 25ª	2ª
S3	6	1	1ª e 2ª coletas	1ª a 6ª	1ª
S4	16	2	1ª e 2ª coletas	11ª a 16ª	2ª

Fonte: Autora

4.3.2 Tratamento do sinal

Nesse tópico há a descrição das técnicas utilizadas no processamento digital dos sinais: pré-processamento, extração de atributos e classificação. A Figura 13 a seguir exhibe os métodos aplicados.

Figura 13 – Métodos aplicados nos dados coletados



Fonte: Autora

A aquisição foi realizada com a taxa de amostragem de 128 Hz, desta forma a cada segundo foram geradas 128 amostras em cada um dos 14 canais. As técnicas foram aplicadas em janelas de 1s (128 amostras), 2.5 s (320 amostras) e 5s (640 amostras).

O sinal foi normalizado via z-score. A média e desvio padrão dos dados de treinamento foram salvos para serem utilizados para normalizar os dados de predição.

Foram utilizados filtros digitais passa-banda que permitem a passagem de frequências numa faixa de valores e atenua as frequências que não estão nessa faixa. O filtro escolhido foi o Butterworth de segunda ordem. As bandas passantes escolhidas foram as seguintes: 7 a 13 Hz (alfa/mu) e 8 a 30 Hz (alfa a beta).

ICA

Foi aplicada a Análise de Componentes Independentes (do inglês *Independent Component Analysis* – ICA) para rejeição de artefatos, RUNICA/EEGLAB. O ICA é capaz de separar fontes lineares independentes de dados de EEG, se estiverem presentes artefatos independentes, a ferramenta é capaz de remove-los. (COMON, 1994; DELORME; MAKEIG, 2004). No entanto, com a segmentação do sinal em trechos de tempo pequenos, não surgiram artefatos para rejeição. Assim, a ferramenta foi aplicada, mas não utilizada.

ERD

ERD e ERS podem ser localizadas no espaço e tempo, segundo Pfurtscheller e Da Silva (1999a). Há algumas formas de medir o ERD/ERS no tempo, Pfurtscheller e Da Silva (1999a)

citam algumas: método da potência de banda, método da variância intertrial, modelos autoregressivos e decomposição espectral, transformação de Hilbert e entre outros.

Kalcher e Pfurtscheller (1995) descrevem o método da variância intertrial (VI) para o cálculo da ERD. O cálculo da VI é feito da seguinte forma: filtra-se o sinal com um filtro passa-banda no ritmo alfa/mu, calcula-se o quadrado da diferença das amostras com sua média e divide pela quantidade de ensaios (KALCHER; PFURTSCHELLER, 1995).

$$IV_{(j)} = \frac{1}{N-1} \sum_{i=1}^{i=N} \{x_{f(i,j)} - \bar{x}_{f(j)}\}^2 \quad (1)$$

Fonte: Kalcher e Pfurtscheller (1995, p.2).

Onde N número total de ensaios, $x_{f(i,j)}$ amostra do i-ésimo ensaio dos dados filtrados, $\bar{x}_{f(i,j)}$ = média de dados na amostra filtradas (KALCHER; PFURTSCHELLER, 1995).

O ERD é quantificado como a alteração percentual da VI da amostra ($A_{(j)}$) em relação à VI em um intervalo de referência (R) (KALCHER; PFURTSCHELLER, 1995).

$$ERD_{(j)} = \frac{R - A_{(j)}}{R} \times 100\% \quad (2)$$

$$com R = \frac{1}{k} \sum_{j=n_0}^{n_0+k} A_{(j)} \quad (3)$$

Fonte: Kalcher e Pfurtscheller (1995, p.2).

Onde R é a VI em um intervalo de referência, em média sobre amostras k; e $A_{(j)}$ é a VI das amostras (KALCHER; PFURTSCHELLER, 1995).

O ERD foi calculado para cada um dos eletrodos. O intervalo de referência utilizado foi a primeira corrida de T0. A partir do ERD, foi montada 3 configurações: a primeira na qual as instancias foi a matriz ERD, a segunda na qual as instâncias foram a matriz ERD mais a relação C3, Cz e C4 de ERD e a terceira na qual as instâncias foram a matriz ERD mais a relação dos 14 eletrodos de ERD, descritas nos próximos tópicos.

Relação de C3, Cz e C4

É possível observar a dessincronização no hemisfério oposto ao evento, como já mencionado, pois ERD/ERS estão relacionadas com a mudança da amplitude do sinal (GRAIMANN, 2002). Baseado nessa premissa, foram escolhidos dois atributos que conseguissem expressar essa discrepância dos hemisférios e consequentemente ajudar na discriminação entre as classes.

Foi definido o atributo “A”, como sendo a divisão dos valores de ERD referentes ao canal posicionado em C3 pelos do canal posicionado em C4. “A” teve o objetivo de colaborar com a classificação entre IME e IMD. Ao ocorrer a imagética de IME, C4 dessincronizava e tinha uma amplitude atenuada em relação a C3 e durante IMD, C3 dessincronizava e tinha sua amplitude diminuída em relação a C4. Assim, “A” durante IME é maior que “A” durante IMD.

O atributo “B” foi definido como a média entre C3 e C4 sobre os valores de referente ao canal posicionado em Cz. “B” foi elaborado com a intenção de evidenciar a presença da imagética de IPED, assim quando ocorria a IPED, a amplitude de Cz diminuía em relação à média de C3 e C4.

$$A = \frac{C_3}{C_4} \quad (4)$$

$$B = \frac{\frac{C_3+C_4}{2}}{C_z} \quad (5)$$

A escolha dos eletrodos C3, C4 e Cz para definir o “A” e “B”, partem também do mapeamento cortical motor do homúnculo de Penfield e Boldrey (1937) e da área de Brodmann (1909).

Montou-se uma matriz híbrida com 16 atributos, os 14 eletrodos de ERD mais “A” e “B”.

Relação dos 14 eletrodos

Estendendo a ideia dos atributos “A” e “B”, foram calculadas 91 combinações possíveis de divisão entre os 14 eletrodos (Exemplo: FC3/FC1, FC3/FCz, FC3/FC2, FC3/FC4, FC3/C3). Dessas 91 combinações foram escolhidas 8 que mais evidenciassem a diferença entre as classes.

Para fazer essa escolha, cada classe foi analisada separadamente. Os dados das 4 classes foram separados em 4 matrizes, nas linhas estavam as instâncias e nas colunas as 91 combinações de divisões entre os eletrodos. Foi calculada a média de cada coluna de cada uma dessas matrizes, formando 4 matrizes de dimensão 1x91. Com as matrizes da média foram calculadas outras 4 matrizes que representassem a diferença entre as classes, por exemplo, a matriz IME de diferença possuía dimensão 3x91 e foi composta pela: diferença entre a matriz média de IME e a matriz média de IMD, diferença entre a matriz média de IME e a matriz média de IPED, e diferença entre a matriz média de IME e a matriz média de T0. Para cada matriz de diferença foi calculado o valor mínimo absoluto de cada coluna. As matrizes com valor mínimo absoluto representavam o valor máximo comum que cada relação de eletrodos (colunas) conseguia atingir ao diferenciar uma classe das demais. Em seguida para fazer a escolha da relação foi observada a coluna que continha o maior valor na matriz do valor mínimo absoluto, essa relação era a que melhor diferenciava uma classe das demais. Foram escolhidas duas relações de eletrodos para cada classe, ou seja, as duas colunas que continham os maiores valores de cada matriz de valor mínimo absoluto de cada classe.

Montou-se uma matriz híbrida com 22 atributos, os 14 eletrodos de ERD mais 2 relações de cada classe.

FFT e PSD

Foi utilizada a FFT para calcular atributos, dentro das janelas analisadas. Os atributos são estimadores matemáticos utilizados por Alomari et al. (2014) em sua análise de sinais de imagética motora, RMS, MAV, IEEG, SSI, VAR e AAC, descritos a seguir. Além deles foram acrescentados a Soma (do inglês *Sum*), Média (do inglês *Mean*), valor Máximo (do inglês *Max*), Logaritmo da Variância (LOGVAR) e Energia (do inglês *Energy*).

1. SUM

$$SUM_i = \sum_{n=1}^N D_i(n) \quad (6)$$

2. MAX

$$MAX_i = \max_{n=1}^N D_i(n) \quad (7)$$

3. MEAN

$$MEAN_i = \frac{1}{N} \sum_{n=1}^N D_i(n) \quad (8)$$

4. RMS

$$RMS_i = \sqrt{\frac{1}{N} \sum_{n=1}^N D_i^2(n)} \quad (9)$$

5. IEEG

$$IEEG_i = \sum_{n=1}^N |D_i(n)| \quad (10)$$

6. MAV

$$MAV_i = \frac{1}{N} \sum_{n=1}^N |D_i(n)| \quad (11)$$

7. VAR

$$VAR_i = \frac{1}{N-1} \sum_{n=1}^N D_i^2(n) \quad (12)$$

8. SSI

$$SSI_i = \sum_{n=1}^N |D_i(n)|^2 \quad (13)$$

9. AAC

$$AAC_i = \frac{1}{N} \sum_{n=1}^N |D_i(n+1) - D_i(n)| \quad (14)$$

10. LOGVAR

$$LOGVAR_i = \log \frac{1}{N-1} \sum_{n=1}^N D_i^2(n) \quad (15)$$

11. ENERGY

$$Energy_i = \sum_{n=1}^N D_i^2(n) \quad (16)$$

Foi estimada a PSD utilizando o método Welch para os estimadores matemáticos citados.

Transformada Discreta de Wavelet

Foi calculada a transformada discreta de wavelet nas famílias: *Daubechies* (db1), *Symlets* (sym1), *Coiflets* (coif1), *Haar* (haar) e *DMeyer* (dmey).

O sinal foi decomposto em 3 níveis, 3 coeficientes de detalhe: cD1 (32 a 64 Hz), cD2 (16 a 32 Hz), cD3 (8 a 16 Hz), sendo utilizado apenas coeficientes de detalhes cD2 e cD3 por conterem as faixas alfa e beta. Os estimadores matemáticos apresentados no tópico anterior foram calculados para os dois coeficientes, assim a matriz de atributos foi composta por 308 características (14 eletrodos*2coeficientes*11estimadores).

Filtro espacial

Os CSP podem ser usados no processamento de sinais com o objetivo de encontrar uma transformação “W” que maximize a variância de sinais associados a uma classe e minimize a variância de sinais a associados à outra classe, em ICM destaca as relações espaciais presentes nos eventos ERD/ERS (VAZ, 2016).

A transformação é dada pela equação 17, onde Ey1 Ey2 são as matrizes de covariância de cada uma das classes (VAZ, 2016).

$$W^* = \arg \min_W \frac{W^T \Sigma^{(Y^2)} W}{W^T \Sigma^{(Y^1)} W} \quad (17)$$

Fonte: Vaz (2016, p.40)

A variância da projeção do sinal é dada por:

$$\tilde{Z}_e = W^{*T} Z_e \quad (18)$$

Fonte: Vaz (2016, p.40)

Onde Z_e é a janela de tempo extraída de um ensaio e (VAZ, 2016)

Guangquan, Gan e Xiangyang (2008) participaram do BCI *Competition* IV-IIA, descreveram seu método utilizando o CSP para 4 classes. Filtraram o sinal de 8 a 30 HZ e removeram artefatos de EOG. Aplicaram o filtro CSP a cada duas classes e depois reduziram a dimensão dos 22 eletrodos para 8 melhores componentes de cada filtro. E calcularam o logaritmo da variância, assim como Vaz (2016), das projeções. Guangquan; Gan e Xiangyang (2008) aplicaram LDA de Fisher para reduzir a dimensão de 48 (8*6 filtros) para 3.

Aqui, para este problema com 4 classes, também foi utilizado 6 filtros CSP, de forma a abranger as combinações possíveis: filtro W1 (IME e IMD), filtro W2 (IME e IPED), filtro W3 (IME e T0), filtro W4 (IMD e IPED), filtro W5 (IMD e T0) e filtro W6 (IPED e T0).

Cada filtro (com dimensão 14 eletrodos) foi também reduzido para 8, assim como Guangquan, Gan e Xiangyang (2008).

Aqui foram calculados como características das projeções a variância, o logaritmo da variância, a variância da FFT e o logaritmo da variância da FFT.

Após serem calculadas as características, assim como Guangquan; Gan e Xiangyang (2008) também foi utilizado o LDA de Fisher para reduzir o espaço amostral para 3.

Classificadores

As máquinas de aprendizado são utilizadas para controle da ICM, aplica-se os atributos selecionados em classificadores para que maximizem a diferença entre classes. O modelo é um classificador treinado com sinais de EEG (com ou sem pré-processamento ou extração de atributos), que é utilizado para prever novos dados de imagética motora baseado nos dados de treinamento.

Foram implementados os seguintes classificadores: Árvore de Decisão (do inglês *Decision Tree* – Tree), LDA, SVM Linear, SVM Quadrático, KNN e Ensemble e LDA, com as configurações apresentadas no Quadro 4.

Quadro 4 – Configuração dos classificadores

Classificadores	Configuração
Tree	Função <code>fitctree</code> (matlab). Árvore de decisão. Validação cruzada= 10 (<i>k-fold</i>); número máximo de splits:4; critério <i>split</i> : índice de diversidade de Gini
LDA	Função <code>fitcdiscr</code> (matlab). Discriminante linear. Validação cruzada= 10 (<i>k-fold</i>).Tipo de discriminante: linear.
SVM Linear	Função <code>fitcecoc</code> (matlab). Máquina de vetor de suporte. Validação cruzada= 10 (<i>k-fold</i>). Função do <i>kernel</i> : linear; nível de restrição de caixa: 1; modo de escala do <i>kernel</i> : automático; Método multiclasse: one-vs-one
SVM Quadrático	Função <code>fitcecoc</code> (matlab). Máquina de vetor de suporte. Validação cruzada= 10 (<i>k-fold</i>). Função do <i>kernel</i> : quadrática; nível de restrição de caixa: 1; modo de escala do <i>kernel</i> : automático; Método multiclasse: <i>one-vs-one</i>
KNN	Função <code>fitcknn</code> (matlab). K-vizinhos mais próximos. Validação cruzada= 10 (<i>k-fold</i>). Número de vizinhos: 1; métrica de distância: euclidiana; peso da distância: equal
Ensemble	Função <code>fitcensemble</code> (matlab). Validação cruzada= 10 (<i>k-fold</i>); tipo de aprendizado: método Ensemble: Bag; Decision tree; número máximo de <i>splits</i> : 239; número de <i>learners</i> : 30.

Fonte: Matlab

5 RESULTADOS E DISCUSSÃO


Os resultados foram divididos em duas partes, a primeira trata da classificação de sinais de imagética motora em um processamento *off-line* utilizando a base de dados da PhysioNet; a segunda parte refere-se aos resultados obtidos com a investigação de métodos capazes de realizar classificação dos sinais bioelétricos em tempo real com dados coletados.

É utilizado como métrica para avaliação dos classificadores e das técnicas a acurácia e o índice *kappa* de Cohen (COHEN, 1960).

5.1 Classificação da imagética *off-line*

Na Figura 14 são comparadas, por meio de *boxplots*, as acurácias e índices *kappa* obtidas nos tipos de análises: os sinais brutos e filtrados em ritmo mu, com 64 e 15 eletrodos, utilizando o classificador MLP. Os 15 eletrodos selecionados estão descritos na seção 4.2.

Figura 14 – Desempenho da classificação individual com dados da base EEGMMIB



Fonte: Autora

A Tabela 2 contém as informações sobre a média e desvio padrão da acurácia e do índice *kappa*, obtidos nas análises realizadas na Figura 14.

Tabela 2 – Desempenho da classificação individual com dados da base EEGMMIB

Eletrodos	Sinal	Acurácia		<i>Kappa</i>	
		Média	DP	Média	DP
64	Bruto	73,1	19,5	0,7	0,23
	Filtrado	36,2	4,5	0,2	0,06
15	Bruto	47,3	15,0	0,3	0,19
	Filtrado	24,9	3,8	0,06	0,05

Fonte: Autora

Foi aplicado o teste de Kolmogorov-Smirnov para cada uma das 4 amostras e foi rejeitada a hipótese nula de distribuição normal. Foi aplicado o teste não paramétrico pareado de Wilcoxon para cada uma das duplas de amostras: sinal bruto com 64 eletrodos e sinal filtrado com 64 eletrodos, sinal bruto com 15 eletrodos e sinal filtrado com 15 eletrodos, sinal bruto com 64 eletrodos e sinal bruto com 15, sinal filtrado com 64 eletrodos e sinal filtrado com 15; em todos os casos a hipótese nula foi rejeitada, ou seja, a mediana das diferenças entre as duplas é diferente de zero. Tem-se que as técnicas não são equivalentes.

Dessa forma, seria preferível utilizar 64 eletrodos ao invés de 15, visto que métricas exibidas na Tabela 2 indicam melhor desempenho e que as técnicas não são equivalentes segundo o teste estatístico. Porém, os 15 eletrodos foram posicionados sobre a área motora na qual a investigação dos sinais bioelétricos é feita, com base na localização das áreas de Brodman (1909) e no sucesso de trabalhos como o de Szczuko (2017) que classificou de sinais de imagética motora com 21 eletrodos sobre o córtex motor. Ademais, essa configuração demanda um esforço computacional inferior e menor incômodo para o sujeito durante a coleta.

Ao filtrar o sinal na faixa de frequência do ritmo alfa/mu, o desvio padrão e a dispersão apresentada no *boxplot* diminuíram, garantindo uma menor variabilidade das métricas independente do sujeito. Porém, as médias das acurácias obtidas nas duas configurações de eletrodos (36,2 % e 24,9 %), bem como no índice *kappa* (0,2 e 0,06), ficaram inferiores aos valores apresentados no sinal bruto, sugerindo a necessidade de outros tratamentos no sinal para viabilizar a classificação com 5 classes.

Classificação em conjunto

A Tabela 3 é referente ao uso de um classificador comum a todos os 30 sujeitos. O classificador treinado com dados dos 30 sujeitos não mostrou resultado satisfatório, em nenhuma das configurações. Apresentando desempenho inferior à média presente na Tabela 2 de classificação individual.

Tabela 3 – Desempenho da classificação em conjunto com dados da base EEGMMIB

Eletrodos	Sinal	Acurácia	<i>Kappa</i>
64	Bruto	50,0	0,38
	Filtrado	26,8	0,09
15	Bruto	33,8	0,17
	Filtrado	21,3	0,018

Fonte: Autora

Distribuição dos erros entres as classes

A matriz de confusão na Tabela 4 é referente a análise em conjunto de dados brutos dos 30 sujeitos com 64 eletrodos. Nas linhas há os valores de referência e nas colunas a previsão da classificação. Nota-se que há uma confusão maior em torno das classes IPED.

Tabela 4 – Matriz de confusão dos dados em conjunto para 64 eletrodos

	IME	IMD	IMED	IPED	T0
IME	4362	1049	697	6625	662
IMD	375	5701	674	5808	844
IMED	297	650	6059	5620	832
IPED	312	631	913	10837	640
T0	266	660	1078	4820	6500

Fonte: Autora


5.2 Classificação da imagética para aplicação em ICM

Foram aplicadas 20 técnicas utilizando os métodos de tratamento de sinal descritos na metodologia com as classes IME, IMD, IPED e T0. As técnicas estão identificadas por siglas que podem ser consultadas no Apêndice A.

Predição com dados *off-line*

A predição com dados *off-line* é referente a experiência com 2 coletas de cada sujeito, uma utilizada para treinamento e a segunda para predição. A Figura 15 exibe o resultado da predição com a segunda coleta em todos os 4 sujeitos em janelas de 1s, 2.5s e 5s. No eixo y encontra-se a porcentagem das melhores acurácias e no eixo x os classificadores especificando o tamanho das janelas. As siglas presentes nas figuras destacam a técnica que obteve o melhor desempenho para um dado classificador em cada uma das 3 janelas.

Figura 15 – Melhores desempenhos *off-line* de S1-S4 em 3 janelas de tempo



Fonte: Autora


Os classificadores mantêm a acurácia na mesma faixa de valores, não havendo um classificador ideal para esses dados em nenhum dos sujeitos. A janela de 5s apresentou resultados melhores na maioria dos experimentos sendo escolhida para ser usada com o avatar. No trabalho de Normand e Ferreira (2015) o aumento do tamanho da janela melhorou classificação dos sinais.

Predição com dados *online*

A predição com dados *online* é referente aos resultados obtidos com o avatar. Nesse experimento o classificador foi treinado com 6 coletas e testado com os dados da aplicação com o avatar, conforme o Quadro 3 presente no protocolo experimental.

A Figura 16 exhibe o desempenho do classificador durante o treinamento, no qual a quantidade de dados foi maior que no experimento anterior, 6 coletas foram utilizadas para treinar o classificador. A fim de reduzir as chances de ocorrência do mal da dimensionalidade (BELLMAN, 1961), visto a grande quantidade de atributos em algumas configurações.

Figura 16 – Desempenho das técnicas com predição *online* – treinamento




Fonte: Autora

As técnicas que fizeram uso do filtro espacial obtiveram melhor acurácia durante o treinamento do classificador, resultado já esperado pelo fato do filtro ter sido projetado sobre esses dados. Além dela, merece destaque a utilização de ERD com e sem os atributos “A” e “B” que na qual o limite superior foi maior que nas demais técnicas e sua mediana está negativamente assimétrica no índice *kappa* e na acurácia.

A Figura 17 exibe o desempenho dos classificadores durante o treinamento, em toda a amostra.

Figura 17 – Desempenho dos classificadores com predição *online* - treinamento




Fonte: Autora

O SVM com *kernel* linear obteve durante o treinamento taxas melhores de classificação, ao observar a mediana nos diagrama de caixa. Todos os classificadores atingem o limite superior, isso acontece pelo fato do uso do CSP como mencionado anterior. O LDA apresentou a maior dispersão e assimetria positiva que ocorreu por influência dos sujeitos e/ou pela variação no desempenho das técnicas.

A Figura 18 exibe a acurácia e índice *kappa* atingidos pelas técnicas com o uso do avatar, em toda a amostra.

Figura 18 – Desempenho das técnicas com a predição *online* – avatar




Fonte: Autora

Houve uma redução da taxa de acerto comparado a fase de treinamento, principalmente com o filtro espacial, ainda assim este atingiu as melhores performances, seguido da configuração a.erd.ab que apresenta limite superior de 70% em sua acurácia. Nota-se que as técnicas com maior dimensão de atributos foram as que obtiveram piores desempenhos, TDW com 308 atributos e as técnicas que fizeram uso de FFT e PSD com 154 atributos.

A Figura 19 exhibe a acurácia e índice *kappa* atingidos pelos classificadores com o uso do avatar, em toda a amostra.

Figura 19 – Desempenho dos classificadores com predição *online* - avatar



Fonte: Autora

Diferente da fase de treinamento, o KNN com uso do avatar obteve mediana semelhante aos demais classificadores, *outliers* acima do limite superior e pouca dispersão, tanto na acurácia quanto no índice *kappa*. Alcançando o melhor desempenho com esses dados.

A Tabela 5 contém o resumo dos melhores desempenhos por sujeito, para cada classificador há as técnicas que apresentaram melhor índices de acurácia e kappa, durante o treinamento e com o avatar.

Tabela 5 – Melhores resultados *online*

Sujeito	Classificador	Técnica	Treinamento		Avatar	
			Ac	Kp	Ac	Kp
S1	Tree	ab.csp.10	61,9	0,49	38	0,17
	LDA	ab.psd	33,5	0,11	40	0,2
	SVM L	a.erd, a.erd.ab, a.erd.v8	37,4	0,17	33	0,1
	SVM Q	a.psd, ab.psd	33	0,11	35	0,13
	KNN	a.csp.fft	62,3	0,5	43	0,23
	Ensemble	a.csp.7, a.csp.10, ab.csp.10 a.fft, a.erd, a.erd.ab, a.erd.v8,	70,2	0,6	30	0,07
	Tree	ab.csp.10	55	0,4	70	0,6
	LDA	a.csp.fft.7, ab.csp.fft.10 ab.psd, a.erd.v8, ab.csp.10,	60,9	0,48	60	0,47
	SVM L	ab.csp.fft.10	60,3	0,47	65	0,53
	SVM Q	ab.csp.10	58,2	0,44	65	0,53
S2	KNN	ab.csp.7, ab.csp.10 a.fft, a.erd.ab, ab.csp.10,	48,2	0,31	50	0,33
	Ensemble	ab.csp.fft.7, ab.csp.fft.10	54,7	0,4	65	0,53
	Tree	a.erd, a.erd.ab, a.erd.v8	30,8	0,08	45	0,27
	LDA	ab.psd, a.csp.7, a.csp.fft.7	70	0,6	45	0,27
	SVM L	a.csp.7, a.csp.fft.7	69,9	0,6	45	0,27
	SVM Q	w.coif1	32,8	0,1	50	0,33
	KNN	ab.fft, a.psd	30,8	0,07	50	0,33
	Ensemble	a.fft	36	0,15	40	0,2
	Tree	a.csp.fft.10	90,2	0,87	75	0,67
	LDA	a.csp.7	88,6	0,85	73	0,63
S3	SVM L	a.csp.7	89,8	0,86	73	0,63
	SVM Q	a.csp.7, a.csp.fft.7	90,5	0,87	70	0,6
	KNN	a.csp.10, a.csp.fft.10	88,3	0,84	80	0,73
	Ensemble	a.csp.fft.10	89,9	0,87	78	0,7
S4	Ensemble	a.csp.fft.10	89,9	0,87	78	0,7

Fonte: Autora

O sujeito S4 obteve 80% de acurácia com o avatar e índice de concordância de 0.73 utilizando o KNN e a.csp.11. O sujeito S2 obteve também resultados satisfatório com índice *kappa* e acurácia utilizando o avatar. Porém, S1 e S3 chegaram apenas a 50% de acerto. Estes realizaram uma quantidade menor de coletas comparado a S2 e S4, as coletas não tiveram *neurofeedback*, porém os sujeitos que passam por mais experiência de imagética motora obtiveram desempenho superior com o avatar. Em Blankertz et al. (2007) e Hwang, Kwon e Im (2009) o *neurofeedback* é uma ferramenta útil para o sucesso da ICM, o treinamento da imagética motora com *feedback* possibilita os sujeitos obterem com mais facilidade a sensação da imagética motora.

Os dados do BCI *Competition* da terceira edição, descritos na Tabela 1, os competidores atingiram índices *kappa* média de 0,63 a 0,79, desempenho semelhante ao obtido com a média dos melhores resultados de S2 e S4 (0,67) da Tabela 5. Os dados da segunda edição os

competidores obtiveram *kappa* médio de 0,29 a 0,57, desempenho semelhante ao obtido com a média dos melhores resultados de S1 e S3 (0,28) da Tabela 5.

No entanto, cada competidor utilizou apenas uma metodologia para todos os sujeitos avaliados. Enquanto os dados coletados, nesse trabalho, atingiram resultados mais acurados com métodos individuais para cada sujeito.

Dos resultados em negritos de cada um dos sujeitos foram montadas matrizes de confusão do teste com o avatar, ver Tabela 6.

Tabela 6 – Matrizes de confusão dos melhores desempenhos com o avatar

		IME	IMD	IPED	T0
S1	IME	6	3	0	1
	IMD	2	7	0	1
	IPED	4	4	0	2
	T0	1	5	0	4
S2	IME	8	0	0	2
	IMD	0	8	2	0
	IPED	0	0	6	4
	T0	2	2	0	6
S3	IME	6	4	0	0
	IMD	6	4	0	0
	IPED	4	4	2	0
	T0	0	2	0	8
S4	IME	9	0	1	0
	IMD	0	7	3	0
	IPED	0	0	9	1
	T0	2	0	1	7

Fonte: Autora

Nota-se que S2 e S4 confundem IMD com IPED e IPED com T0. S1 e S3 confundem IME com IMD e IMD com IME, além de possuírem poucos acertos na classe IPED. Comportamento semelhante entre os que obtiveram bons resultados e os que obtiveram acurácias menores, porém não semelhante a matriz de confusão da base PhysioNet apresentada na Tabela 4.

Cada um dos sujeitos apresentou mais facilidade durante a imagética de algumas classes: S1 em IMD, S2 em IME e IMD igualmente, S3 em T0 e S4 IME e IPED igualmente.

6 CONCLUSÃO

Neste trabalho foi proposta uma metodologia para classificação de sinais de EEG de imagética motora de membros inferiores e superiores, para classificação *off-line*, usando uma abordagem onde os atributos são os próprios eletrodos. Foram investigadas técnicas de análise do sinal bruto, filtrado no ritmo mu, com 64 e 15 eletrodos utilizando o MLP com uma única camada com 20 neurônios. Nesses experimentos foi possível observar possibilidade de classificação de 5 classes sem realizar tratamento nos sinais de EEG, porém, esse método não foi adequado para toda amostra analisada, visto a dispersão do desempenho entre os sujeitos, sendo assim, necessário o uso de técnicas que diminuam variabilidade do desempenho entre os sujeitos, mas de forma que este seja satisfatório para discriminação entre as classes. A filtragem no ritmo mu diminuiu a dispersão do desempenho entre os sujeitos, porém somente esse pré-processamento não foi suficiente para alcançar uma acurácia satisfatória. Além disso, foi testada possibilidade de classificação com número reduzido de eletrodos, localizados sobre a área motora, que mostrou desempenho inferior para os dados da base PhysioNet nas técnicas propostas.

Também foi investigada a possibilidade de construir um classificador geral para os sinais de todos os voluntários. O que não foi possível, dada a influência de outros fatores, tais como representação cortical diferente entre indivíduos (ELBERT, 1995) a variedade na frequência alfa (DOPPELMAYR, 1998), além de fatores que não estão claros na descrição da base de dados.

Assim, foram implementadas, com os dados coletados, 20 técnicas tratamento de sinal e 6 arquiteturas de classificadores a fim de encontrar um método capaz de permitir a melhor discriminação entre as 4 classes escolhidas para metodologia *online*. Porém, não foi estabelecido um método único para ICM proposta, sendo mais adequado para cada sujeito um método particular que atingiu os melhores índices.

A metodologia *off-line* com os dados coletados, utilizando 1 coleta para o treinamento e 1 coleta para o teste do classificador não foi capaz de generalizar os dados da segunda coleta, mesmo aumentando o tamanho da janela de tempo. No entanto, ao aumentar a quantidade de coletas para 6 no treinamento, o classificador foi capaz de generalizar a entrada de novos dados com o avatar.

Apesar da implementação de diversos métodos, a fim de encontrar um capaz de realizar a classificação das 4 classes de forma adequada, a dificuldade de generalização dos dados só

foi superada com o aumento da quantidade de dados no treinamento e com a presença da prática mental (DICKSTEIN; DEUTSCH, 2007).

A prática mental influenciou o resultado, pois metade da amostra (S2 e S4) que realizou mais coletas obteve desempenho superior em relação à S1 e S3 que fizeram apenas 6 coletas. Com o uso de *neurofeedback* a prática mental que pode ser aperfeiçoada (BLANKERTZ et al., 2007; HWANG; KWON; IM, 2009).

Por fim, implementação da ICM com as 4 classes obteve bom desempenho com alguns métodos, porém com parte da amostra. Atingindo acurácia *online* de 80% para um dado sujeito e com média de 60,75% para a amostra avaliada.

7 PERSPECTIVAS E CONSIDERAÇÕES FINAIS

A interface-cérebro máquina tem como objetivo permitir pessoas com mobilidade reduzida, ausência de membros ou deficiência motora conseguirem realizar tarefas cotidianas ou de entretenimento por meio de uma interface gráfica ou física (como cadeira de rodas, próteses) (WOLPAW et al., 2002; BASHASHATI et al., 2007).

A aplicação da ICM com o avatar é somente uma aplicação que permite visualizar *online* o reconhecimento de padrões de sinais neurais. Este trabalho abre perspectivas para que sejam construídos módulos de aquisição e processamento de dados de EEG aptos a captar a imagética motora de seres humanos. A fim de poderem ser utilizados em contextos clínicos e sociais, trazendo reintegração e funcionalidade aos seres humanos com algum tipo de limitação motora.

O êxito da ICM não dependeu somente da escolha das técnicas de tratamento do sinal, das arquiteturas de classificadores escolhidas e da quantidade de dados para treinamento, mas também da variável que segregou o desempenho da amostra – a prática mental. A ausência da prática mental, nos métodos analisados nesse trabalho, foi uma barreira para o sucesso do ICM em alguns sujeitos.

Assim, espera-se que este trabalho contribua com pesquisas que tratem de reconhecimento de múltiplas classes de imagética motora *online* em aplicações na engenharia biomédica.

REFERÊNCIAS

- ABREU, Marjory Cristiany da Costa. **Analisando o desempenho do ClassAge**: um sistema multiagentes para classificação de padrões. 2006. 149f. Dissertação (Mestrado em Sistemas e Computação) – Departamento de Informática, Universidade Federal do Rio Grande do Norte, Natal, 2006.
- ALOMARI, Mohammad H.; BANIYOUNES, Ali M.; AWADA, Emad A. EEG-Based Classification of Imagined Fists Movements using Machine Learning and Wavelet Transform Analysis. **International Journal of Advancements in Electronics and Electrical Engineering**, New York, v. 3, n. 3, p. 83–87, sep, 2014.
- ALOMARI, Mohammad H. et al. Wavelet-based feature extraction for the analysis of EEG signals associated with imagined fists and feet movements. **Computer and Information Science**, Toronto, v. 7, n. 2, p. 17-27, mar, 2014.
- ALOMARI, Mohammad H. Mind Controlled Universal TV Remote Control. **Proceedings of 2016 International Conference on Image Processing, Production and Computer Science (ICIPCS'2016)**, Londres, p.85-91, mar, 2016
- ALOMARI, Mohammad H.; SAMAHA, Aya; ALKAMHA, Khaled. Automated classification of L/R hand movement EEG signals using advanced feature extraction and machine learning. **International Journal of Advanced Computed Science and Applications**, v.4, n.6, p. 207-212, 2013.
- AZIMIRAD, V. et al. Analysis of PSO, AIS and GA-based optimal wavelet-neural network classifier in brain–robot interface. **Innovation and Research in BioMedical engineering**, v. 36, n. 4, p. 240-249, jun, 2015.
- BARBOSA, André F. et al. Implementação de Classificador de Tarefas Mentais Baseado em EEG. In: Congresso brasileiro de redes neurais, 9., 2009, Ouro Preto/MG. **Anais...** Ouro Preto/MG, 2009.
- BASHASHATI, Ali et al. A survey of signal processing algorithms in brain–computer interfaces based on electrical brain signals. **Journal of Neural engineering**, v. 4, n. 2, p. R32-R57, mar, 2007.
- BASTOS, Aline Furtado et al. Simulação Mental de Movimentos: Da Teoria à Aplicação na Reabilitação Motora. **Revista Neurociencias**, v. 21, n. 4, p. 604-619, 2013.
- BCI Competition III**. 2005. Disponível em: <<http://www.bbc.de/competition/iii/>>. Acesso em 20 de dezembro de 2017.
- BCI Competition III - Resultados IIIa**. 2005. Disponível em: <<http://www.bbc.de/competition/iii/results/index.html#graz1>>. Acesso em 20 de dezembro de 2017.
- BCI Competition IV**. 2008. Disponível em: <<http://www.bbc.de/competition/iv/>>. Acesso em 20 de dezembro de 2017.
- BCI Competition IV - Resultados IIa**. 2008. Disponível em: <<http://www.bbc.de/competition/iv/results/index.html#dataset2a>>. Acesso em 20 de dezembro de 2017.

BLANKERTZ, Benjamin et al. The BCI competition III: Validating alternative approaches to actual BCI problems. **IEEE transactions on neural systems and rehabilitation engineering**, v. 14, n. 2, p. 153-159, 2006.

BLANKERTZ, Benjamin et al. The non-invasive Berlin brain-computer interface: fast acquisition of effective performance in untrained subjects. **NeuroImage**, v. 37, n. 2, p. 539-550, 2007.

BELLMAN, Richard. **Adaptive control processes**. Princeton: Princeton University Press, 1961.

BERGER, Hans. Über das elektrenkephalogramm des menschen. **European Archives of Psychiatry and Clinical Neuroscience**, v. 87, n. 1, p. 527-570, 1929.

BRASIL. IBGE. **Censo Demográfico, 2000**. Disponível em: <<https://www.ibge.gov.br/estatisticas-novoportal/sociais/populacao/2098-np-censo-demografico/9662-censo-demografico-2010.html?edicao=9749>>. Acesso em 21 de setembro de 2017.

BRODMANN, K. **Vergleichende Lokalisationslehre der Grosshirnrinde**: in ihren Prinzipien dargestellt auf Grund des Zellenbaues. Leipzig: J. A. Barth, 1909.

CABLOCO, Luís Otávio. **Artefatos**. Unidade de Pesquisa e Tratamento das Epilepsias. Hospital de São Paulo (UNIFESP). Departamento de Neurofisiologia Clínica. Hospital Israelita Albert Einstein. Material *online*. Notas de aulas. 2013. Disponível em: <<http://www.itarget.com.br/newclients/sbnc.org.br/arquivos/aulas/aula-2.pdf>>. Acesso em 21 de setembro de 2017.

COHEN, Jacob. A coefficient of agreement for nominal scales. **Educational and psychological measurement**, v. 20, n. 1, p. 37-46, 1960.

COMON, Pierre. Independent component analysis, a new concept?. **Signal processing**, v. 36, n. 3, p. 287-314, 1994.

COSTA, Renato Carrasco; OLIVEIRA, Vanessa Mendes de. **Um estudo sobre interface cérebro-computador**. 2012. 67 f. Monografia (Bacharelado em Ciência da Computação) – Instituto de Ciências Exatas, Universidade de Brasília, Brasília, 2012.

DEECKE, Lüder; GRÖZINGER, Berta; KORNHUBER, H. H. Voluntary finger movement in man: cerebral potentials and theory. **Biological cybernetics**, v. 23, n. 2, p. 99-119, 1976.

DELORME, Arnaud; MAKEIG, Scott. EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. **Journal of neuroscience methods**, v. 134, n. 1, p. 9-21, 2004.

DICKSTEIN, Ruth; DEUTSCH, Judith E. **Motor imagery in physical therapist practice**. Physical therapy, v. 87, n. 7, p. 942-953, 2007.

DOPPELMAYR, Michael et al. Individual differences in brain dynamics: important implications for the calculation of event-related band power. **Biological cybernetics**, v. 79, n. 1, p. 49-57, 1998.

DOUD, Alexander J. et al. Continuous three-dimensional control of a virtual helicopter using a motor imagery based brain-computer interface. **PloS one**, v. 6, n. 10, p. e26322, 2011.

EEGMMIDB. **EEG Motor Movement/Imagery Dataset**, 2009. Disponível em: <<http://www.physionet.org/pn4/eegmmidb/>>. Acesso em 02 agosto de 2016.

ELBERT, Thomas et al. Increased cortical representation of the fingers of the left hand in string players. **Science**, v. 270, n. 5234, p. 305, 1995.

FARIAS, Felipe Costa. **Interface cérebro-máquina: reconhecimento de sinais cerebrais através de reservóir computing**. 2014. 38f. Monografia (Trabalho de conclusão de curso de Engenharia da Computação) – Escola Politécnica, Universidade de Pernambuco, Recife, 2014.

GANONG, William. **Fisiologia médica**. Tradução: Carlos Henrique Cosendey, Denise Costa Rodrigues, Patricia Vouex. Revisão técnica: Antonio Nóbrega. 22ª ed – Porto Alegre: AMGH Editora LTDA. 2010.

GANONG, William F. **Fisiologia médica**. Tradução: Sidney A. Camara. São Paulo: Atheneu editora. 1969.

GOLDBERGER, A. L. et al. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. **Circulation**, v. 101, n. 23, p. e215-e220, 2000.

GÓMEZ-HERRERO, Germán et al. Automatic removal of ocular artifacts in the EEG without an EOG reference channel. In: **Signal Processing Symposium; NORSIG**. Proceedings of the 7th Nordic. IEEE, p. 130-133. 2006.

GRAIMANN, B. et al. Visualization of Significant ERD/ERS Patterns in Multichannel EEG and ECoG data. **Clinical Neurophysiology**. v. 113, n.1, p. 43-47, 2002.

GUANGQUAN, Liu; GAN, Huang e XIANGYANG, Zhu. **BCI Competition IV-IIa**. Descrição do método empregado por Liu Guangquan, Huang Gan e Zhu Xiangyang (Escola de Engenharia Mecânica, Xangai Jiao Tong University). Disponível em: <http://www.bbc.de/competition/iv/results/ds2a/LiuGuangquan_desc.txt>. Acesso em 20 de dezembro de 2017.

HALL, Mark et al. The WEKA data mining software: an update. **ACM SIGKDD explorations newsletter**, v. 11, n. 1, p. 10-18, 2009.

HANDIRU, Vikram Shenoy; PRASAD, Vinod A. Optimized Bi-Objective EEG Channel Selection and Cross-Subject Generalization With Brain–Computer Interfaces. **IEEE Transactions on Human-Machine Systems**, v. 46, n. 6, p. 777-786, 2016.

HOUSSAY, Bernardo A. **Fisiologia Humana**. 5ª ed. Guanabara Koogan. 1980

HUANG, Dandan et al. Electroencephalography (EEG)-based brain–computer interface (BCI): A 2-D virtual wheelchair control based on event-related desynchronization/synchronization and state control. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 20, n. 3, p. 379-388, 2012.

HWANG, Han-Jeong; KWON, Kiwoon; IM, Chang-Hwang. Neurofeedback-based motor imagery training for brain–computer interface (BCI). **Journal of neuroscience methods**, v. 179, n. 1, p. 150-156, 2009.

JASPER, Herbert H. The ten twenty electrode system of the international federation. **Electroencephalography and clinical neurophysiology**, v. 10, p. 371-375, 1958.

JEANNEROD, Marc. Mental imagery in the motor context. **Neuropsychologia**, v. 33, n. 11, p. 1419-1432, 1995.

KALCHER, J.; PFURTSCHELLER, G. Discrimination between phase-locked and non-phase-locked event-related EEG activity. **Electroencephalography and clinical neurophysiology**, v. 94, n. 5, p. 381-384, 1995.

KHALIFA, Wael; ROUSHDY, Mohamed I.; SALEM, Abdel-Badeeh M. A Rough Set Approach for User Identification Based on EEG Signals. **Egyptian Computer Science Journal**, v. 38, n. 3, 2014.

KOVÁCS, Z. L. **Redes neurais artificiais**: fundamentos e aplicações. Edição acadêmica – São Paulo. 1996.

LAL, Thomas Navin et al. Support vector channel selection in BCI. **IEEE transactions on biomedical engineering**, v. 51, n. 6, p. 1003-1010, 2004.

LEEB, Robert et al. Self-paced (asynchronous) BCI control of a wheelchair in virtual environments: a case study with a tetraplegic. **Computational intelligence and neuroscience**, v. 2007, p. 1-9, 2007.

LINHARES, Sérgio; GEWANDSZNAJDER, Fernando. **Biologia**: Série Brasil. Ensino médio/volume único. 1ª edição, 3ª impressão - São Paulo: Ática. 2005

LOPES, Sônia. **Bio**. Ensino médio/volume único. 1ª ed – São Paulo: Saraiva, 2004.

LUGER, George F. **Inteligência artificial**: estruturas e estratégias para a solução de problemas complexos. Tradução Paulo Engel. 4 ed – Porto Alegre: Bookmann, 2004.

MASON, Steven G.; BIRCH, Gary E. A general framework for brain-computer interface design. **IEEE transactions on neural systems and rehabilitation engineering**, v. 11, n. 1, p. 70-85, 2003.

MCCULLOCH, Warren S.; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, n. 4, p. 115-133, 1943.

MCFARLAND, Dennis J. et al. Mu and beta rhythm topographies during motor imagery and actual movements. **Brain topography**, v. 12, n. 3, p. 177-186, 2000.

NEUROBOTS. **Neurobots**: Pesquisa e desenvolvimento. Disponível em: <<http://www.neurobots.com.br/>>. Acesso em 01 de setembro de 2017.

EMOTIV. **Emotiv Epoc +**. Disponível em: <<https://www.emotiv.com/epoc/>>. Acesso em 01 de setembro de 2017.

NICOLELIS, Miguel AL; BIRBAUMER, Niels; MÜLLER, Klaus Robert. Special issue on brain-machine interfaces. **IEEE Transactions on Biomedical Engineering**, v. 51, n. 6, p. 877-880, 2004.

NOMENCLATURE, Standard Electrode Position. American Electroencephalographic Society Guidelines for. **Journal of clinical Neurophysiology**, v. 8, n. 2, p. 200-202, 1991.

NORMAND, Rogerio; FERREIRA, Hugo Alexandre. Superchords: decoding EEG signals in the millisecond range. **PeerJ PrePrints**, 2015.

NYKOPP, Tommi. **Statistical Modeling Issues for the Adaptive Brain Interface**. Dissertação de Mestrado – Departamento de Engenharia Elétrica e de Comunicações, Helsinki University of Technology, Espoo, Finlândia, 2001.

OCHOA, Jorge Baztarrica. EEG signal classification for brain computer interface applications. **Ecole Polytechnique Federale de Lausanne**, v. 7, p. 1-72, 2002.

ONOSE, G. et al. On the feasibility of using motor imagery EEG-based brain-computer interface in chronic tetraplegics for assistive robotic arm control: a clinical test and long-term post-trial follow-up. **Spinal cord**, v. 50, n. 8, p. 599, 2012.

PARENTE, Regina Rosa. **Abordagem de construção de arquitetura homogênea para comitês via meta-aprendizagem**. 2012. 126 f. Dissertação (Mestrado em Ciência da Computação) - Universidade Federal do Rio Grande do Norte, Natal, 2012

PENFIELD, Wilder; BOLDREY, Edwin. Somatic motor and sensory representation in the cerebral cortex of man as studied by electrical stimulation. **Brain: A journal of neurology**. V. 60, Issue 4, p. 389–443, 1937.

PFURTSCHELLER, Gert. EEG event-related desynchronization (ERD) and event-related synchronization (ERS). **Electroencephalography: Basic principals, clinical applications and related fields**, p. 958-967, 1999.

PFURTSCHELLER, G. et al. EEG-based discrimination between imagination of right and left hand movement. **Electroencephalography and clinical Neurophysiology**, v. 103, n. 6, p. 642-651, 1997.

PFURTSCHELLER, Gert; ARANIBAR, A. Evaluation of event-related desynchronization (ERD) preceding and following voluntary self-paced movement. **Electroencephalography and clinical neurophysiology**, v. 46, n. 2, p. 138-146, 1979.

PFURTSCHELLER, Gert; DA SILVA, F.H. Lopes. Event-related EEG/MEG synchronization and desynchronization: basic principles. **Clinical neurophysiology**, v. 110, n. 11, p. 1842-1857, 1999a.

PFURTSCHELLER, G.; DA SILVA, F. H. L. **Handbook of electroencephalography and clinical neurophysiology—event-related desynchronization**. Elsevier, Amsterdam, The Netherlands, 1999b.

PFURTSCHELLER, Gert; NEUPER, Christa. Motor imagery activates primary sensorimotor area in humans. **Neuroscience letters**, v. 239, n. 2, p. 65-68, 1997.

RASHID, Md Mamun Or; AHMAD, Mohiuddin. Classification of motor imagery hands movement using levenberg-marquardt algorithm based on statistical features of EEG signal. In: **Electrical Engineering and Information Communication Technology (ICEEICT), 2016 3rd International Conference on**. IEEE, p. 1-6, 2016.

REZENDE, Solange Oliveira. **Sistemas inteligentes: fundamentos e aplicações**. Baueri, SP: Editora Manole, 2003.

REZENDE, Solange Oliveira. **Sistemas Inteligentes: Fundamento e aplicações**. Barueri, SP: Manole, 2005.

RUSSEL, Stuart; NORVING, Peter. **Inteligência artificial: tradução da segunda edição**/Stuart Russeel, Peterr Norving; tradução de PubliCare Consultoria. – Rio de Janeiro: Elsevier, 2004.

SCHALK, G. et al. BCI2000: A General-Purpose Brain-Computer Interface (BCI) System. **IEEE Transactions on Biomedical Engineering**, v. 51, n. 6, p. 1034-1043, 2004.

SCHERER, Reinhold et al. Toward self-paced brain–computer communication: navigation through virtual worlds. **IEEE Transactions on Biomedical Engineering**, v. 55, n. 2, p. 675-682, 2008.

SHENOY, H. Vikram; VINOD, A. Prasad. An iterative optimization technique for robust channel selection in motor imagery based Brain Computer Interface. In: **Systems, Man and Cybernetics (SMC), 2014 IEEE International Conference on**. IEEE, p. 1858-1863, 2014.

SZCZUKO, Piotr. Real and imaginary motion classification based on rough set analysis of EEG signals for multimedia applications. **Multimedia Tools and Applications**, v. 76, n. 24, p. 25697-25711, 2017.

TANGERMANN, Michael et al. Review of the BCI competition IV. **Frontiers in neuroscience**, v. 6, p. 55, 2012.

TANNUS, Alexandre Moraes. **Controle de uma cadeira de rodas utilizando potencial evocado visual**. 2014. 92 f. Dissertação (Mestrado em Engenharia Elétrica) - Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, Belo Horizonte. 2014.

TAVELLA, Michele et al. Towards natural non-invasive hand neuroprostheses for daily living. In: **Engineering in Medicine and Biology Society (EMBC), 2010 Annual International Conference of the IEEE**. IEEE, p. 126-129, 2010.

TOLIĆ, Martina; JOVIĆ, Franjo. Classification of wavelet transformed EEG signals with neural network for Imagined mental and motor tasks. **Kineziologija**, v. 45, n. 1, p. 130-138, 2013.

VAZ, Yule. **Extração de características para a classificação de imagética motora em interfaces cérebro-computador**. 2006. 111 f. Dissertação (Mestrado em Ciências - Ciências da Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2016.

VAZ, Yule; DE MELLO, Rodrigo Fernandes. Emprego de Banco de Filtros e do Teorema de Imersão de Takens em Padrões Espaciais para a Classificação de Imagética Motora em Interfaces Cérebro-Computador. **Revista de Informática Teórica e Aplicada**, v. 23, n. 2, p. 165-192, 2016.

WOLPAW, Jonathan R. et al. Brain–computer interfaces for communication and control. **Clinical neurophysiology**, v. 113, n. 6, p. 767-791, 2002.

XU, Baoguo; SONG, Aiguo. Pattern recognition of motor imagery EEG using wavelet transform. **Journal of Biomedical Science and Engineering**, v. 1, n. 01, p. 64, 2008.

YANG, Su; DERAVIDI, Farzin. Novel HHT-based features for biometric identification using EEG signals. In: **Pattern Recognition (ICPR), 2014 22nd International Conference on**. IEEE, p. 1922-1927, 2014.

YANG, Su; DERAVIDI, Farzin. On the effectiveness of eeg signals as a source of biometric information. In: **Emerging Security Technologies (EST), 2012 Third International Conference on**. IEEE, p. 49-52, 2012.

YANG, Su; DERAVIDI, Farzin. Quality filtering of EEG signals for enhanced biometric recognition. In: **Biometrics Special Interest Group (BIOSIG), 2013 International Conference of the**. IEEE, p. 1-4, 2013.

ZHANG, Xiang et al. Enhancing Mind Controlled Smart Living Through Recurrent Neural Networks. **KDD 2017**, Halifax, Nova Scotia Canada, 2017.

APÊNDICE A – SIGLAS DAS TÉCNICAS

Préfixo

‘a’: filtrado em alfa

‘ab’: filtrado de alfa a beta

‘w’: TDW

Infixo/sufixo

‘fft/psd’: uso do 11 estimadores matemáticos

csp.7: estimador VAR

csp.10: estimador LOGVAR

fft.7: estimador VAR

fff.10: estimador LOGVAR

‘ers’: ERD

Sufixo

‘ab’: adiciona dois atributos A e B da matriz ERD.

‘v8’: adiciona mais 8 atributos (relação de eletrodos) da matriz ERD.

Famílias wavelet

db1, sym1, coif1, haar, dmey.