



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

MARIA KAROLINE DA SILVA ANDRADE

**DETECÇÃO E CLASSIFICAÇÃO DE IMAGÉTICA MOTORA UTILIZANDO SINAIS
DE EEG E APRENDIZADO DE MÁQUINA**

Recife
2019

MARIA KAROLINE DA SILVA ANDRADE

**DETECÇÃO E CLASSIFICAÇÃO DE IMAGÉTICA MOTORA UTILIZANDO SINAIS
DE EEG E APRENDIZADO DE MÁQUINA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Biomédica, da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Engenharia Biomédica.

Área de concentração: Computação Biomédica.

Orientador: Prof. Dr. Marcelo Cairrão de Araújo Rodrigues.

Coorientador: Prof. Dr. Wellington Pinheiro dos Santos.

Recife
2019

Catálogo na fonte
Bibliotecária Margareth Malta, CRB-4 / 1198

A553d Andrade, Maria Karoline da Silva.
Detecção e classificação de imagética motora utilizando sinais de EEG e
aprendizado de máquina / Maria Karoline da Silva Andrade. - 2019.
56 folhas, figs., gráfs. tab.

Orientador: Prof. Dr. Marcelo Cairrão de Araújo Rodrigues.
Coorientador: Prof. Dr. Wellington Pinheiro dos Santos.

Dissertação (Mestrado) – Universidade Federal de Pernambuco.
CTG. Programa de Pós-Graduação em Engenharia Biomédica, 2019.
Inclui Referências e Apêndice.

1. Engenharia Biomédica. 2. Interface cérebro-máquina. 3.
Imagética motora. 4. Eletroencefalograma. 5. Inteligência artificial. 6.
Classificadores inteligentes. I. Rodrigues, Marcelo Cairrão de Araújo.
(Orientador). II. Santos, Wellington Pinheiro dos. (Coorientador). III.
Título.

UFPE

610.28 CDD (22. ed.) BCTG/2019-241

MARIA KAROLINE DA SILVA ANDRADE

**DETECÇÃO E CLASSIFICAÇÃO DE IMAGÉTICA MOTORA UTILIZANDO SINAIS
DE EEG E APRENDIZADO DE MÁQUINA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Biomédica, da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Engenharia Biomédica.

Aprovada em: 01/07/2019.

BANCA EXAMINADORA

Prof. Dr. Marcelo Cairrão de Araújo Rodrigues (Orientador)
Universidade Federal de Pernambuco

Prof. Dr. Ricardo Yara (Examinador Interno)
Universidade Federal de Pernambuco

Dr. Washington Wagner Azevedo da Silva (Examinador Externo)
Universidade Federal de Pernambuco

Dedico este trabalho às Universidades Públicas, e a todos que estão lutando pela sobrevivência delas nestes tempos sombrios.

AGRADECIMENTOS

Agradeço primeiramente a Deus, porque Dele, por Ele e para Ele são todas as coisas.

Agradeço a minha família - meus pais e minha irmã - por sempre me apoiarem.

Agradeço a minha namorada Maíra Santana, pela companhia, pela ajuda, e incentivo desde a graduação, não me deixando desistir no meio do caminho.

Agradeço ao meu orientador Marcelo Cairrão e ao meu coorientador Wellington P. dos Santos, por compartilharem comigo seus conhecimentos, e acima de tudo me lembrarem de que nosso intuito é produzir ciência para melhorar a qualidade de vida da sociedade em que vivemos.

Agradeço ao Departamento de Engenharia Biomédica, aos secretários Rangel e Juliana, pela disposição para me ajudar.

Agradeço aos meus colegas de trabalho pela compreensão em todos os momentos em que tive que me dividir entre o trabalho e o mestrado, em especial, a minha supervisora e amiga, Marcela Oliveira, que sempre me apoiou, e me ensina todos os dias a ser uma boa profissional.

Agradeço as minhas amigas Flávia, Gabriela, Giuliana, Marília e Thamires, que me mostram todos os dias como nós, mulheres, somos fortes e maiores que todo o machismo impregnado na sociedade.

A todos vocês, todo o meu carinho e gratidão.

RESUMO

A Interface Cérebro Máquina tem-se mostrado uma tecnologia promissora para desenvolvimento de dispositivos que venham a auxiliar pessoas com algum déficit motor em suas atividades de vida diária, principalmente com uso da imagética motora, que é a resposta cerebral dada no ato de imaginar um movimento real, ainda que o membro relacionado ao movimento não exista. Há de se considerar ainda a plasticidade neural, uma característica do cérebro que o torna capaz de realizar novas conexões, desta forma, até mesmo os indivíduos com um pequeno dano cerebral poderia estar apto ao uso de uma Interface Cérebro Máquina, com o devido treinamento. Dentre as diversas formas de captar os sinais cerebrais o Eletroencefalograma é uma técnica de baixo custo, não invasiva, e capaz de fornecer informações do córtex cerebral de maneira satisfatória, principalmente com o avanço das técnicas computacionais, capazes de eliminar os ruídos advindos dos processos de aquisição. Neste trabalho é realizado um estudo do desempenho de classificadores inteligentes na separação de movimentos da imagética motora, relacionados a movimentos das mãos e pés. Para tal, os sinais foram decompostos em sete níveis com a transformada de Wavelet, e utilizados os seguintes atributos: Coeficiente, Desvio padrão, Energia, Entropia, Média, *Range* e *Skewness*, extraídos de todos os níveis. Os testes foram efetuados com os classificadores: *Bayes Net*, *Naive Bayes*, *Multilayer Perceptron*, *Support Vector Machine*, *Extreme Learning Machine*, *Morphological Extreme Learning Machine*, *J48*, *Random Forest* e *Random Tree*, onde foi possível obter resultados de acurácia acima de 99%, acompanhados de Kappa superiores a 0,9, que levaram a entender que a abordagem inicial foi eficiente e pode ser utilizada para futuras avaliações com diversos indivíduos a fim de verificar sua reprodutibilidade.

Palavras-chave: Interface cérebro-máquina. Imagética motora. Eletroencefalograma. Inteligência artificial. Classificadores inteligentes.

ABSTRACT

The Brain Machine Interface has been shown to be a promising technology. It is being used to develop devices that may help people with motor disabilities in their daily activities. One of the main methods is motor imagery. It is the brain response to the act of imagining a real movement, even if the member related to the movement does not exist. An important aspect to be considered is neural plasticity. It is a brain characteristic that makes it capable of making new connections. So even individuals with a small brain damage could be able to use a Brain Machine Interface after a proper training. Among the many ways of acquiring brain signals, the electroencephalogram has some benefits. It is a low-cost, non-invasive technique. It may provide satisfactory information from the cerebral cortex. Moreover, the most modern equipment are able to remove most of the noise arising from acquisition. In this study we access intelligent classifiers performance in the differentiation of motor imagery signals related to movements of the hands and feet. For this, the signals were decomposed into seven levels using Wavelet transform. The following features were extracted from all levels: Coefficient, Standard deviation, Energy, Entropy, Mean, Range and Skewness. We performed tests with the classifiers: Bayes Net, Naïve Bayes, Multilayer Perceptron, Support Vector Machine, Extreme Learning Machine, Morphological Extreme Learning Machine, J48, Random Forest and Random Tree. Achieving results of accuracy above 99% and Kappa statistic higher than 0.9. Thus, we found that the initial approach was efficient. It has the potential to be used for future evaluations with several individuals, in order to verify experiment's reproducibility.

Keywords: Brain-machine interface. Motor imagery. Electroencephalogram. Artificial intelligence. Intelligent classifiers.

LISTA DE FIGURAS

Figura 1 - Modelo de Interface Cérebro Máquina.....	16
Figura 2 - Principais desafios no desenvolvimento de Interfaces Cérebro-Máquina	19
Figura 3 - Estrutura de um neurônio.....	22
Figura 4 - Estrutura matemática de um neurônio artificial	22
Figura 5 - Exemplo de nó em um classificador Bayesiano	24
Figura 6 - Representação do BayesNet	24
Figura 7 - Representação de uma rede MLP	25
Figura 8 - Representação da arquitetura de uma SVM	26
Figura 9 - Arquitetura de uma ELM	27
Figura 10 - Representação de uma árvore de busca	28
Figura 11 - Desenho esquemático do método seguido neste estudo.....	37
Figura 12 - Posicionamento dos eletrodos	37
Figura 13 - Setas indicativas do movimento a ser imaginado	38
Figura 14 - Esquema sequencial de uma <i>trial</i>	39
Figura 15 - Vetores aleatórios para cada um dos movimentos.	39
Figura 16 - Esquema da utilização da Transformada de Wavelet	40
Figura 17 - Exemplo de matriz de confusão	42
Figura 18 - BoxPlot: Acurácia <i>versus</i> melhores configurações dos classificadores	46
Figura 19 - BoxPlot: Kappa <i>versus</i> melhores configurações dos classificadores.....	47

LISTA DE TABELAS

Tabela 1 - Áreas de aplicação das Interfaces Cérebro-Máquina.....	17
Tabela 2 - Métodos de aquisição de sinais cerebrais e suas características	18
Tabela 3 - Atividades eletrofisiológicas utilizadas em interfaces cérebro-máquina	18
Tabela 4 - Métodos de extração de atributos e suas características.....	21
Tabela 5 - Funções para diferentes tipos de kernel	27
Tabela 6 - Expressões para os operadores morfológicos	28
Tabela 7 - Resumo dos trabalhos relacionados e suas principais características.....	35
Tabela 8 - Expressões matemáticas para cada um dos atributos	40
Tabela 9 - Parâmetros utilizados para representar as imagens durante a etapa de classificação	41
Tabela 10 - Métricas de avaliação do desempenho da classificação	42
Tabela 11 - Classificação de acordo com o coeficiente Kappa	42
Tabela 12 - Valores médios de acurácia e kappa	43
Tabela 13 - Valores médios e desvio padrão do erro médio absoluto e do tempo de treino	44
Tabela 14 - Matriz de confusão pior resultado de acurácia - Naive Bayes.....	45
Tabela 15 - Matriz de confusão melhor resultado de acurácia - SVM	45
Tabela 16 - Resumo dos resultados obtidos	48

SUMÁRIO

1	INTRODUÇÃO	12
1.1	CONTEXTO E MOTIVAÇÃO	12
1.2	OBJETIVOS	14
1.2.1	Objetivos específicos	14
1.3	ORGANIZAÇÃO DO TRABALHO	15
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	INTERFACE CÉREBRO-MÁQUINA	16
2.2	PRINCÍPIOS DE RECONHECIMENTO DE PADRÕES	19
2.2.1	Análise de Componente Principal (PCA)	20
2.2.2	Análise de Componente Independente (ICA)	20
2.2.3	Padrão Espacial Comum (CSP)	20
2.2.4	Transformada de Wavelet	21
2.3	REDES NEURAIS ARTIFICIAIS	21
2.3.1	Redes Neurais Bayesianas	23
2.3.2	Multilayer Perceptron	24
2.3.3	Support Vector Machine	26
2.3.4	Extreme Learning Machine	27
2.4	ÁRVORES DE BUSCA	28
2.5	CONSIDERAÇÕES	29
3	TRABALHOS RELACIONADOS	30
3.1	ESTADO DA ARTE	30
3.2	CONSIDERAÇÕES	35
4	MATERIAIS E MÉTODOS	37
4.1	AQUISIÇÃO DE SINAL E BASE DE DADOS	37
4.2	SEGMENTAÇÃO DO SINAL	39

4.3	PRÉ-PROCESSAMENTO E EXTRAÇÃO DE ATRIBUTOS.....	40
4.4	CLASSIFICAÇÃO.....	41
5	RESULTADOS E DISCUSSÃO	43
5.1	CONSIDERAÇÕES	47
6	CONCLUSÃO.....	49
6.1	LIMITAÇÕES.....	50
6.2	CONTRIBUIÇÕES.....	50
6.3	TRABALHOS FUTUROS	50
	REFERÊNCIAS.....	51
	APÊNDICE A - An EEG brain-computer interface to classify motor imagery signals.....	56

1 INTRODUÇÃO

Nesse capítulo é apresentada a problemática e as motivações envolvidas no desenvolvimento desse trabalho, bem como os objetivos estabelecidos para seu cumprimento.

1.1 CONTEXTO E MOTIVAÇÃO

De acordo com a Organização Mundial de Saúde (OMS), até 2030, dois bilhões de pessoas farão uso de ao menos um dispositivo assistivo. Ainda de acordo com a OMS, pela primeira vez na história, a maioria das pessoas tem uma expectativa de 60 anos ou mais. Considerando que esta população, em sua maioria, tem sua capacidade funcional reduzida, ela está propensa à necessidade de dispositivos assistivos para manter uma qualidade de vida, e pode influenciar ainda mais na estimativa apresentada (BORG; LARSSON; ÖSTERGREN, 2011; BAUER; ELSAESSER; ARTHANAT, 2011; Organização Mundial de Saúde, 2015).

A tecnologia assistiva, pode vir ainda a ajudar indivíduos acometidos com doenças progressivas, que comprometem de maneira definitiva a execução de tarefas motoras, como a Esclerose Múltipla Amiotrófica (ELA) e a Doença de Parkinson. O comprometimento motor, e até mesmo cognitivo pode vir ainda através da Paralisia Cerebral, Acidente Vascular Cerebral (AVC) e danos oriundos de traumas a medula espinhal e/ou ao cérebro (DALY; WOLPAW; CLEVELAND, 2008). O desenvolvimento destas tecnologias ainda está centralizado em países desenvolvidos, ou emergentes. De acordo com a OMS, apenas uma em cada dez pessoas em situação de pobreza tem acesso à tecnologia assistiva, isto se deve em parte ao fato que o custo associado ao desenvolvimento ainda é elevado, e a falta de conhecimento até mesmo da existência destes dispositivos (ARTHANAT, 2011; BAUER; ELSAESSER; BORG; LARSSON; ÖSTERGREN, 2011; EIDE; ØDERUD, 2009; MARTIN et al., 2008; SCHERER, 2005; SCHERER; GLUECKAUF, 2005; World Health Organization, 2007).

A revolução 4.0 tem intensificado o uso da Inteligência Artificial (IA) no âmbito da saúde. Esta técnica tem se mostrado cada vez mais útil, podendo ser aplicada no auxílio de diagnósticos, seja por análise de imagens, DNA, ou grandes bases de

dados com informações de sintomas; neste caso, a IA proporciona além de maior agilidade, uma redução da possibilidade de erros humanos (JIANG et al., 2017).

A Interface Cérebro Máquina é uma das ferramentas que faz uso da Inteligência Artificial, mais precisamente do aprendizado de máquina, e pode ser utilizada como uma tecnologia assistiva, principalmente nos casos em que é comprometimento do sistema nervoso, onde os produtos assistivos não são muito eficazes. Ela proporciona através de sinais cerebrais, a comunicação entre o cérebro e um dispositivo sem que haja necessidade de qualquer estímulo motor. Quanto ao método de aquisição de sinais pode ser classificada como invasiva, ou não invasiva, sendo este um ponto crucial de análise de viabilidade (MILLÁN et al., 2010). A plasticidade dos neurônios é uma característica favorável às possibilidades de aplicação da Interface Cérebro Máquina, ela permite que o cérebro aprenda novas funções, desta forma, ainda que haja um dano cerebral em alguma área, é possível que este se adapte utilizando outra área (DALY; WOLPAW; CLEVELAND, 2008).

O método de aquisição mais utilizado atualmente para Interfaces Cérebro Máquina é o de Eletroencefalograma (EEG), ele permite uma aquisição de custo relativamente baixo, com maior facilidade que outras técnicas não invasivas, e proporciona sinais que podem ser analisados com as ferramentas computacionais já existentes (SAHA et al., 2017; MILLÁN et al., 2010).

Dentre as diversas áreas de aplicação da Interface Cérebro Máquina, merece destaque o desenvolvimento de próteses. Atualmente, as próteses comerciais utilizam sinais mioelétricos para controle dos movimentos, o que implica na necessidade de músculos remanescentes, inviabilizando o uso para indivíduos acometidos de perda total de membro. Outro limitante das próteses existentes é o grau de liberdade em especial para membro superior. A Interface Cérebro Máquina pode proporcionar também o controle de softwares, possibilitando comunicação e até mesmo realização de ativação de dispositivos utilizados no dia a dia, como TV, computadores, etc. Em se tratando especialmente do controle de software, o desenvolvimento de jogos sérios tem crescido, eles possibilitam a realização de atividades de reabilitação de uma maneira muito menos tediosa e cansativa; além disso, os jogos, no geral, podem proporcionar entretenimento, e comunicação social, o que influencia diretamente na qualidade de vida dos indivíduos (AL-TIMEMY et al.,

2013; AL-TIMEMY et al., 2016; BERGMEISTER et al., 2016; CONTROZZI et al., 2017; DYSON; BARNES; NAZARPOUR, 2018; GHAZAEI et al., 2017; ISON; ARTEMIADIS, 2014; KHUSHABA et al., 2016; KHUSHABA et al., 2017; LIU, 2014; MILLÁN et al., 2010; SCHEME; ENGLEHART, 2011).

Com base no exposto, e considerando que ainda há muito que desenvolver em termos de mobilidade e resposta temporal das interfaces cérebro máquina, este trabalho propõe uma avaliação do desempenho de métodos inteligentes na diferenciação de sinais da imagética motora, buscando a aplicabilidade em interfaces.

1.2 OBJETIVOS

Buscando contribuir no avanço do desenvolvimento de Interfaces Cérebro Máquina destinadas a pessoas com comprometimento motor, este trabalho tem por objetivo avaliar a capacidade de diferenciação da imagética motora dos movimentos das mãos e pés, fazendo uso de sinais de EEG, e métodos inteligentes de classificação.

1.2.1 Objetivos específicos

Para obtenção do objetivo principal, foram estabelecidos os seguintes objetivos específicos:

- Realização de revisão bibliográfica e estado da arte, com ênfase em métodos inteligentes e interfaces cérebro máquina;
- Formação de base de dados de sinais de EEG de imagética motora;
- Processamento dos sinais da base de dados;
- Realizar a extração de atributos do sinal;
- Avaliar o desempenho dos métodos inteligentes;

1.3 ORGANIZAÇÃO DO TRABALHO

A organização deste trabalho se deu da seguinte maneira: O primeiro capítulo destina-se a problemática do tema abordado, expondo a motivação para escolha deste, e contextualização na sociedade atual; O segundo capítulo aborda conceitos importantes para compreensão das técnicas adotadas neste estudo, com foco em redes neurais, e reconhecimento de padrões; O terceiro capítulo mostra o estado da arte para o uso de Interface Cérebro Máquina, com seus desafios e principais métodos de aprendizado de máquina utilizados; No quarto capítulo temos o descritivo de como este trabalho foi executado, onde estão presentes todos os materiais e métodos utilizados; No quinto capítulo, se tem os resultados e uma análise quantitativa deles, com as devidas considerações; Por fim, no sexto capítulo, a conclusão, onde temos as contribuições deste trabalho e as dificuldades encontradas, bem como as possibilidades de trabalhos futuros.


2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo serão abordados os conceitos dos temas que guiam esta pesquisa. Nele será possível entender o funcionamento de uma Interface Cérebro Máquina, e seus desafios para aplicações, bem como das técnicas computacionais escolhidas para realização do experimento proposto.

2.1 INTERFACE CÉREBRO-MÁQUINA

Uma Interface Cérebro Máquina é um sistema onde há uma comunicação entre o cérebro e um computador, ou qualquer outro dispositivo externo, por meio da atividade cerebral. Na Figura 1, tem-se um modelo de ICM.

Figura 1 - Modelo de Interface Cérebro Máquina



Fonte: A Autora (2019).

Há diversas áreas de aplicação para ICM, e dentre as principais e mais promissoras pode-se destacar a aplicação em próteses, controladas sem a necessidade de atividade elétrica muscular; em dispositivos que permitem a comunicação de pessoas com síndrome de *locked-in* ou outras síndromes que impeçam a comunicação oral, ou escrita; em dispositivos para locomoção de pessoas com comprometimento motor total, etc. A ICM pode ainda proporcionar

melhores informações sobre as atividades cerebrais, visto que fornece um *feedback* em tempo real (SAHA et al., 2019). Na Tabela 1, temos outras aplicações.

Tabela 1 - Áreas de aplicação das Interfaces Cérebro-Máquina

Área de aplicação	Exemplos
Reabilitação neural	Indução de plasticidade.
	Controle de objeto virtual com uso de eletrodos internos.
	Indução de estimulação muscular, substituindo o sistema nervoso central.
	Tratamento de depressão severa.
Interface Cérebro-Cérebro	Transferência de informação cognitiva.
Robótica e tecnologias assistivas	Controle de robôs.
	Controle de próteses de membros superiores e/ou inferiores.
	Controle de dispositivos de locomoção.
Aplicações clínicas	Tratamento de patologias, tais como esclerose lateral amiotrófica, paralisia cerebral, acidente vascular cerebral, danos à medula espinhal, distrofias musculares e neuropatias crônicas periféricas.
Outros	Controle de realidade virtual, vídeo games, identidade cerebral, identificação humoral, <i>brain painting</i> .

Fonte: A Autora (2019).

A ICM pode ser classificada de três formas de acordo com a resposta cerebral, são elas: ativa, quando a atividade reflete a intenção voluntária do usuário, independente de estímulos externos; passiva, quando a resposta reflete a intenção implícita do usuário, utilizando informações cognitivas para transmitir seu estado real; e a reativa, neste caso a resposta ocorre em reação a uma estimulação externa (ZANDER; KOTHE, 2011).

Há diversos métodos para captação dos sinais cerebrais, que podem ser classificados como invasivos e não invasivos. Os métodos invasivos são menos utilizados, por serem mais delicados e custosos, devido aos riscos que apresentam, porém possuem uma melhor relação sinal-ruído, e são capazes de fornecer informações mais precisa da fonte dos sinais registrados, são eles os eletrodos intracorticais invasivos e eletrocorticograma (ECoG). Dentre os métodos não invasivos temos: magnetoencefalograma (MEG), *doppler* transcraniano funcional, ressonância magnética funcional (fMRI), espectroscopia funcional de infravermelho (NIRS) e eletroencefalograma (EEG). Seguem na Tabela 2 abaixo algumas características destes.

Tabela 2 - Métodos de aquisição de sinais cerebrais e suas características

Método de aquisição	Natureza	Tipo de medição	Resolução temporal	Resolução espacial	Procedimento	Portabilidade
EEG	Elétrica	Direta	~0,05s	~10mm	Não invasivo	Portátil
MEG	Magnética	Direta	~0,05s	~5mm	Não invasivo	Não portátil
ECoG	Elétrica	Direta	~0,003s	~1mm	Invasivo	Portátil
Registro neural intracortical	Elétrica	Direta	~0,003s	~0,05mm - ~0.5mm	Invasivo	Portátil
fMRI	Metabólica	Indireta	~1s	~1mm	Não invasivo	Não portátil
NIRS	Metabólica	Indireta	~1s	~5mm	Não invasivo	Portátil

Fonte: A Autora (2019).

Merece destaque o eletroencefalograma, método mais utilizado, por se tratar de uma ferramenta com uso relativamente simples, e de baixo custo, quando comparado a outras técnicas. Ele registra as atividades geradas pelo disparo de neurônios cujos potenciais pós-sinápticos chegam à camada mais superficial do córtex, podendo ser captados por eletrodos de superfície (HAAS, 2003) (PURVES et al., 2004).

Os neuromecanismos são os responsáveis por proporcionarem os sinais das atividades captadas pelos métodos citados anteriormente, segue em Tabela 3, abaixo, o descritivo de alguns deles, sendo todos passíveis de captação através do EEG.


Tabela 3 - Atividades eletrofisiológicas utilizadas em interfaces cérebro-máquina

Neuromecanismo	Breve descrição
Atividade sensorimotora	Alterações no ritmo cerebral (mu, Beta e gamma).
Potenciais corticais lentos (SCPs)	Potenciais relacionados a movimento. Alterações lentas, e não-motoras geradas pelo indivíduo. Elas refletem um mecanismo de regularização do limiar de mobilizações excitatórias locais.
P300	Pico positivo presente no EEG 300ms após um estímulo significativo (auditivo, visual ou somatosensorial).
Potencial evocado visual (VEPs)	Gerados em resposta a um estímulo visual. Suas propriedades estão diretamente relacionadas à natureza do estímulo.
Resposta a atividades mentais	Padrões de sinais cerebrais gerados por tarefas mentais não motoras (cálculo mental, imaginação de objetos).
Atividades de células neurais (ANC)	Taxa de disparo de neurônios ativados pela execução de movimentos.
Neuromecanismos múltiplos (MNs)	Combinação de dois ou mais neuromecanismos.

Fonte: A Autora (2019).

Os desafios para o desenvolvimento de Interfaces Cérebro Máquina abrangem diversas áreas do conhecimento, podemos citar como exemplo a dinâmica cerebral, que possui ainda muitos mecanismos com funcionamentos integrados desconhecidos. Segue na Figura 2, abaixo, um resumo com os principais desafios encontrados nas diversas áreas.

Figura 2 - Principais desafios no desenvolvimento de Interfaces Cérebro-Máquina



Fonte: A Autora (2019).

2.2 PRINCÍPIOS DE RECONHECIMENTO DE PADRÕES

O reconhecimento de padrões pode se dar de duas maneiras: supervisionada, onde há um conhecimento *a priori* das características do problema; e não supervisionada, quando não há o conhecimento *a priori*, e o conjunto de dados é separados em grupos, onde os pontos destes grupos são similares entre si.

Para que haja o reconhecimento de padrões, é necessário que os objetos a serem reconhecidos sejam caracterizados. Em termos de Classificação Inteligente, estas características são os atributos. Nas sessões seguintes abordaremos os principais métodos de extração de atributos aplicados a Interfaces Cérebro Máquina.

2.2.1 Análise de Componente Principal (PCA)

Trata-se de um método de extração de atributos estatísticos, que utilizando uma transformação linear, converte um conjunto de observações com possível relação em um conjunto não correlacionado, chamado de componente principal. É gerado então um conjunto de componentes a partir dos dados de entrada, onde o primeiro componente principal tem a maior variância possível.

Vale destacar que a PCA nem sempre fornece uma boa classificação, visto que os melhores componentes discriminantes podem não estar nos componentes principais, o que não garante uma otimização da classificação. A PCA reduz ainda a dimensão dos dados, efetuando a busca de uma nova representação ideal em termos de erro médio quadrático mínimo, entre a representação e os dados originais. Pode ser também utilizado como método de redução de ruídos.

2.2.2 Análise de Componente Independente (ICA)

A Análise de Componente Independente é um método estatístico que separa um conjunto de sinais mistos em fontes, sem informações prévias da natureza deste sinal, pressupondo que as fontes são independentes do ponto de vista estatístico. Por exemplo, a ICA considera cada canal de um ECG uma fonte independente.

A ICA é mais utilizada como uma ferramenta de pré-processamento, principalmente para remoção de ruídos, porém, só há sucesso nesta aplicação quando os ruídos são independentes do sinal.

2.2.3 Padrão Espacial Comum (CSP)

O Padrão Espacial Comum (do inglês Common Spatial Pattern, CSP) é um método que utiliza uma transformação linear, na qual um espaço multidimensional tem sua dimensão diminuída, representado em uma matriz de projeção, onde cada linha consiste no peso das dimensões de entrada; esta transformação maximiza a variância de matrizes de sinais de duas classes. Neste caso, as diferenças são maximizadas e as semelhanças são minimizadas. O método baseia-se na diagonalização simultânea da matriz de covariância das duas classes.

2.2.4 Transformada de Wavelet

A Transformada de Wavelet é uma ferramenta matemática que permite a extração de características de diversos tipos de dados. Destacam-se também pelos bons resultados obtidos mesmo que com sinais não estacionários, e por permitir o estudo de sinais no domínio do tempo e da frequência. Divide-se em contínua (CWT) e discreta (DWT), onde, a discreta diminui a análise redundante de frequências realizada pela contínua. Na Tabela 4, temos um resumo dos principais métodos de extração de atributos e suas características.

Tabela 4 - Métodos de extração de atributos e suas características


Método	Características
PCA	- Transformação linear. - Transformação de conjunto de variáveis correlacionadas em não correlacionadas. - Otimização dos dados em termos do erro médio quadrático. - Pode ser utilizado como filtro para ruídos não relacionados ao sinal.
ICA	- Separa um sinal em suas fontes independentes. - Assume independência estatística mútua entre as fontes. - Bom para remoção de artefatos não relacionados ao sinal.
CSP	- Desenvolvido para problemas binários. Atualmente existem extensões multiclases. - Indicado para interface cérebro-máquina síncrona. - Sensível à resolução espacial.
CWT	- Fornece informações em tempo e frequência. - Bom desempenho para sinais não estacionários.
DWT	- Fornece informações em tempo e frequência. - Bom desempenho para sinais não estacionários. - Menos complexo que a CWT.

Fonte: A Autora (2019).

2.3 REDES NEURAIS ARTIFICIAIS

Os neurônios (Figura 3) são as células sinalizadoras do sistema nervoso, capazes de se comunicar de maneira rápida e eficaz com outras células em qualquer parte do corpo humano. Existem no mínimo mil tipos de neurônios, porém, a complexidade do sistema nervoso está mais relacionada à organização destes do que a esta variedade. Uma rede neural biológica é o conjunto de neurônios, que interagem entre si, de maneira complexa, não linear e paralela, capaz de realizar processamentos muito mais rápidos que os melhores computadores existentes na atualidade (KANDEL et al., 2014; HAYKIN, 2009).

Figura 3 - Estrutura de um neurônio




Fonte: Adaptado de Kandel et al. (2014).

Um neurônio é composto por: corpo celular, dendritos, axônio e terminais pré-sinápticos. Os dendritos apicais e basais são responsáveis por receber os sinais de outras células nervosas, estes sinais reúnem-se no corpo celular e são enviados a outras células através de uma única via o axônio, que tem em seu fim terminais pré-sinápticos. Vale ressaltar que esta comunicação ocorre sempre de maneira unidirecional, dos dendritos aos terminais pré-sinápticos (KANDEL et al., 2014).

As Redes Neurais Artificiais (RNAs) são redes computacionais que baseiam seu funcionamento no sistema nervoso humano, capazes de aprender e armazenar conhecimentos experimentais, e tem como base uma unidade de processamento simples, o neurônio artificial (Figura 4).

Figura 4 – Estrutura matemática de um neurônio artificial



Fonte: A Autora (2019).

Assim como o neurônio biológico, o neurônio artificial tem diversos sinais de entrada $x_1, x_2, \dots, x_m$, oriundos da camada de entrada, com pesos ($w_1, w_2, \dots, w_m$), que se assemelham as sinapses. Os sinais devidamente ponderados são transmitidos a um somador (corpo celular), que recebe ainda um *bias* externo que determinará se os sinais serão inibidos, transmitidos ou alterados, com isto uma saída será produzida que terá sua amplitude determinada por uma função de ativação. Esta saída pode ser representada pela Equação 1.

$$y_k = \varphi(v_k + b_k) \quad (1)$$

onde b é o *bias*.

Há diversos modelos de RNAs, que se diferenciam por suas camadas intermediárias, quantidade de neurônios, função de transferência e algoritmo de aprendizado.

2.3.1 Redes Neurais Bayesianas


As RNAs Bayesianas têm como princípios básicos: o teorema probabilístico de Bayes, e a Inferência Bayesiana. Considerando $A_1, A_2, \dots, A_i$ eventos que formam um conjunto S , e B um evento independente, com probabilidade $P(B) > 0$, podemos definir o teorema de Bayes pela Equação 2.

$$P(A_i|B) = \frac{P(B|A_i) \cdot P(A_i)}{P(B)} = \frac{P(B|A_i) \cdot P(A_i)}{\sum_i P(B|A_i) \cdot P(A_i)} \quad (2)$$

onde A_i são eventos causadores do evento B , sendo a probabilidade deste evento atuar na ocorrência de B , calculada antes do evento acontecer, uma probabilidade *a priori*. Caso o evento aconteça verdadeiramente após o experimento, a probabilidade *a priori* é revista e passa a ser aplicada aos eventos A_i uma probabilidade *a posteriori*, sendo esta a Inferência Bayesiana.

Dentre os principais classificadores Bayesianos tem-se o Naive Bayes e o BayeNet. O Naive Bayes considera que os eventos de entrada não possuem relação de dependência entre si. Como pode ser visto, na Figura 5, em sua estrutura há um nó, a classe, que da origem a todos os outros.


Figura 5 – Exemplo de nó em um classificador Bayesiano



Fonte: A Autora (2019).

Em contrapartida o BayesNet considera que há uma dependência probabilística entre os nós, desta forma, calcula-se a probabilidade condicional de um nó de acordo com os valores atribuídos aos outros nós, fornecendo assim uma probabilidade a posteriori. A resposta do classificador será o valor do nó com a classe que tiver a maior probabilidade a posteriori. Na Figura 6, temos a representação do BayesNet.

Figura 6 – Representação do BayesNet




Fonte: A Autora (2019).

2.3.2 Multilayer Perceptron

Na Figura 7, temos a representação de uma rede MLP, na qual, podemos observar que há apenas uma camada de entrada e uma camada de saída, e quantidade variável de camadas intermediárias. Outra observação pertinente a respeito da MLP é que ela pode ser totalmente conectada, isto é, os neurônios de uma camada podem estar conectados a todos os neurônios da camada anterior.

Figura 7 – Representação de uma rede MLP



Fonte: A Autora (2019).

Há três características fundamentais de uma MLP: sua função de ativação de cada neurônio é não linear; a rede possui ao menos uma camada intermediária com neurônios que não pertencem à camada de entrada e/ou saída; há um alto grau de conectividade definido pelos pesos sinápticos.

Os parâmetros variáveis de uma MLP consistem em: quantidade de camadas intermediárias, quantidade de neurônios ocultos, taxa de aprendizagem, momentum, iterações. A quantidade de camadas intermediárias e neurônios ocultos são escolhidos empiricamente de acordo com o problema estudado, desejando-se a menor quantidade possível para que não haja elevação desnecessária no custo computacional. Quanto à taxa de aprendizagem e o momentum, podem ser escolhidos buscando-se o menor número de iterações possíveis, e considerando as seguintes questões: devem produzir uma convergência a um mínimo local ou global na superfície de erro, ou uma convergência para uma configuração da rede que tenha a melhor generalização sob o espaço de entrada.

Em se tratando de generalização, esta pode ser influenciada pelos seguintes fatores: o tamanho e a qualidade dos dados de treinamento, ou seja, o quanto ele representa estes dados, a arquitetura da rede e a complexidade do problema. Como não se tem controle sob a complexidade do problema, se trabalha com o conjunto de treinamento e a arquitetura da rede, ainda sim, fazendo uso de heurísticas. Uma das

formas de estimar um conjunto de treinamento ideal está descrita de acordo com a Equação 3 abaixo.

$$N = O\left(\frac{W}{\epsilon}\right) \quad (3)$$


onde W são os parâmetros livres, pesos e níveis de bias, da rede, ϵ a fração de erro permitida, e O a ordem da quantidade entre parênteses.

A MLP é uma rede indicada para resolução de problemas não lineares, porém, em casos de problemas de alta complexidade podem demandar um alto custo computacional sendo esta uma desvantagem sua.

2.3.3 Support Vector Machine

A *Support Vector Machine* (SVM) é uma máquina de aprendizagem que tem como premissa a construção de um hiperplano ótimo, no qual a margem de separação entre exemplos diferentes é a máxima possível. A arquitetura de uma SVM está representada na Figura 8.

Figura 8 – Representação da arquitetura de uma SVM



Fonte: A Autora (2019).

Esta máquina utiliza um vetor de suporte que é extraído dos dados de treinamento, que junto ao vetor de entrada, forma o núcleo do produto interno. O uso do hiperplano é ideal para problemas lineares, portanto, quando se trata de

problemas não lineares, a SVM mapeia seu conjunto de treinamento do espaço original, para um novo espaço de maior dimensão, para isto, ela faz o uso de Kernels. Os tipos de Kernels mais utilizados são o polinomial, o RBF ou Gaussiano e o Sigmoidal, cujas características funções definidas na Tabela 5.

Tabela 5 – Funções para diferentes tipos de kernel

Tipo de Kernel	Função $K(x_i, x_j)$	Parâmetros
Polinomial	$(\delta(x_i \cdot x_j) + \kappa)^d$	δ, κ e d
Gaussiano	$e^{-\sigma \ x_i - x_j\ ^2}$	σ
Sigmoidal	$\tanh(\delta(x_i \cdot x_j) + \kappa)$	δ e κ


Fonte: A Autora (2019).

Se comparada a MLP, a SVM tem a vantagem de não ter sua complexidade aumentada com a dimensão do problema a ser resolvido, o que a faz robusta para uso com problemas de grandes dimensões.

2.3.4 Extreme Learning Machine

A *Extreme Learning Machine*, trata-se de uma Rede Neural Artificial de camada única *feedforward*, que contorna os problemas de definição do número de neurônios e dos pesos de entrada, característicos do uso de *backpropagation*. Nela estes parâmetros são aleatórios, o que maximiza a capacidade de generalização. A Figura 9, mostra a arquitetura de uma ELM genérica com saída única.

Figura 9 – Arquitetura de uma ELM



Fonte: A Autora (2019).

A função de ativação $f(x)$ de uma ELM é uma função aleatória, podendo ser qualquer função contínua, geralmente utiliza-se uma função não linear (ZHANG et al., 2017). Em casos em que não se conhece a função de ativação, é possível fazer o uso de Kernels, assim como na SVM, o kernel mapeia os dados de entrada relevantes em um espaço de características. Além dos Kernels comuns apresentados anteriormente, existem também os Kernels morfológicos, desenvolvidos por Azevedo et al. (2015), baseados nos operadores morfológicos definidos na Tabela 6 abaixo:

Tabela 6 – Expressões para os operadores morfológicos


Operação	Expressão
Dilatação	$(f \oplus g)(u) = \bigvee_{v \in S} f(v) \wedge g(u - v)$
Erosão	$(f \ominus g)(u) = \bigwedge_{v \in S} f(v) \vee \bar{g}(v - u)$

Fonte: A Autora (2019).

2.4 ÁRVORES DE BUSCA

As árvores de busca são estruturas de decisão relativamente simples, onde a partir de um nó raiz, são feitos questionamentos, até que se alcance um nó folha. Na Figura 10 temos a representação de um exemplo de árvore de busca. É uma técnica de aprendizado que pode ser utilizada tanto para regressão como para classificação.

Figura 10 – Representação de uma árvore de busca



Fonte: Russell; Norvig (2013).

Há diversos algoritmos que utilizam árvores de decisão, dentre os mais utilizados temos: *Random Tree*, onde os atributos são selecionados aleatoriamente como nó raiz, até que se ache a melhor configuração; *Random Forest*, este algoritmo utiliza uma combinação aleatória de árvores de decisão, que resolvem o problema dado de maneira independente, tendo como resultado final a solução que mais se repetir entre suas árvores; e o J48, neste caso o atributo mais significativo é definido como nó raiz.

2.5 CONSIDERAÇÕES

Os elementos dos conceitos aqui apresentados podem proporcionar o desenvolvimento de dispositivos que venham a auxiliar no aumento da qualidade de vida de diversas pessoas com comprometimento motor e/ou cognitivo, através do uso de Interfaces Cérebro Máquina.

3 TRABALHOS RELACIONADOS

Este capítulo será composto de revisões de trabalhos que abordam a interface cérebro máquina, incluindo suas aplicações e características.

3.1 ESTADO DA ARTE

Um dos principais fatores para o sucesso com o uso de inteligência artificial é a escolha de atributos que consigam caracterizar bem o padrão a ser analisado. Em seu trabalho Samuel et al. (2017) optou por utilizar 32 atributos, de tempo e frequência, para caracterizar os sinais de EEG obtidos de quatro indivíduos com amputação de membro superior, o objetivo principal do trabalho consistiu em diferenciar cinco movimentos de imagética motora da mão, sendo eles: mão aberta e fechada, supinação e pronação do punho, e ausência de movimento. Para tal, foi utilizado um EEG de 64 canais, com eletrodos dispostos de acordo com o sistema 10-20. Os participantes foram submetidos a sessões onde imagens dos movimentos a serem imaginados eram dispostos em um monitor à frente deles, durante 5s, com intervalos de 5s entre si para relaxamento muscular. Os algoritmos utilizados para realizar a classificação dos sinais foram *Linear Discriminant Analysis*, *Multilayer Perceptron*, *Support Vector Machine* e *Fisher Linear Discriminant*. Para avaliar o desempenho dos classificadores utilizou-se a acurácia, tendo sido obtidos resultados acima de 99%. Além disto, o estudo observou também qual a banda de frequência cerebral com maior influencia na quantidade de informação neural em se tratando da imagética motora de membros superiores, sendo estas as bandas de frequência entre 0.1-40Hz e 14-30Hz.

Em contrapartida, Zhang et al. (2017) optou por utilizar as seguintes combinações como atributos: coeficiente autoregressivo e entropia aproximada; decomposição de wavelet e coeficiente autoregressivo. A base de dados do experimento é composta por sinais de EEG adquiridos com 6 eletrodos, de sete indivíduos, os quais foram orientados a executar as seguintes tarefas: relaxar, não executando nenhuma tarefa mental, esta seria a linha de base; imaginar um bloco dimensional, previamente apresentado, girando em torno de um eixo; executar um cálculo mental; imaginar uma carta para um amigo, ou parceiro; imaginar números sendo escrito em um quadro negro, sequencialmente, com o próximo número sendo escrito apenas quando o anterior é apagado. Para classificação, foi utilizado o

algoritmo *Support Vector Machine*, com variação de Kernel Polinomial de 1 a 12, e uso do Kernel RBF. Os melhores valores de acurácia foram observados para Kernels de 6 a 12, com valores acima de 90%. Quando comparados entre si, os atributos que geraram as melhores classificações foram os da combinação da decomposição de wavelet e coeficiente autoregressivo.

Outra maneira de se escolher atributos é observando o padrão de comportamento dos sinais registrados, Kayikcioglu e Aydemir (2010) em seu trabalho observaram padrões de curva ascendentes e descendentes que correspondiam ao registro do EEG de um indivíduo que realizava um experimento de movimentar um cursor na tela para baixo e para cima, de acordo com as orientações dadas. A aquisição dos sinais foi realizada com uso de seis eletrodos, dispostos de acordo com o sistema 10-20, e uma taxa de amostragem de 256Hz. Foram utilizados conjuntos de sinais diferentes para teste e treino, compostos de 268 e 293 movimentos, respectivamente, a janela de cada movimento foi de 3,5s. Para os atributos, após definir um polinômio de segunda ordem para caracterizar os sinais relacionados aos movimentos, os coeficientes do polinômio foram utilizados como atributos, a classificação foi realizada com k-NN, *Support Vector Machine* com kernel RBF e *Multilayer Perceptron*, sendo o melhor valor de acurácia obtido pelo k-NN com 90,6% para k=9.

A identificação dos movimentos finos, como os realizados com os dedos, é um dos desafios da Interface Cérebro Máquina, que utiliza EEG e tem os movimentos de membros superiores como objetivo. Com base nisso Alazrai, Alwanni e Daoud (2018) realizaram um experimento a fim de diferenciar os movimentos dos dedos de uma mesma mão. Os sinais utilizados foram captados de 18 indivíduos saudáveis, os quais realizaram doze movimentos com os dedos da mão direita. O experimento consistiu na realização dos movimentos dos dedos apresentados em um monitor, posicionado a frente dos participantes, podendo ser de flexão seguida de extensão, ou adução seguida de abdução, os movimentos foram realizados cinco vezes para cada dedo. Para análise dos sinais foi utilizada uma abordagem com a distribuição de Choi-Willimas, e uma estrutura de classificação de duas camadas, a fim de classificar o dedo que realizava o movimento e qual movimento estaria sendo realizado, foi também utilizado para classificação o algoritmo SVM com Kernel RBF. Os melhores resultados foram obtidos com o método de classificação de duas

camadas proposto, e mostraram-se bastante variáveis entre os indivíduos, com acurácias variando de 58,9% a 96,5% para o movimento do mesmo dedo. Em se tratando da identificação do movimento que estava sendo realizado, foram obtidas as seguintes acurácias: 76,6% para flexão e 67,2% para extensão do dedo médio.

Ainda em se tratando de movimentos mais refinados, Jochumsen, Khan e Dremstrup (2015) utilizaram sinais de EEG como dados para diferenciar três movimentos com a mesma mão, sendo eles as pinças: palmar, lateral e de precisão. Os sinais foram provenientes de experimentos com 14 indivíduos, que realizaram cada movimento 100 vezes, com intervalos de 1min entre blocos de 25 movimentos, e 9s entre os movimentos; e adquiridos por um equipamento de 25 canais, os eletrodos foram dispostos de acordo com o sistema 10-20, no hemisfério cortical esquerdo. O pré-processamento dos sinais envolveu a separação dos mesmos em movimentos, se tratando do momento de execução da tarefa e 2s anteriores, e em *background*, referente ao período de 5 a 3s antes da execução do movimento; com uso de uma janela de 1s com sobreposição de 200ms foram extraídos atributos temporais e espectrais, que passaram ainda por uma etapa de seleção com uso do *sequential forward selection* (SFS). Para classificação foi utilizado o *Linear Discriminant Analysis* (LDA), que obteve como melhores resultados: acurácia de até 78% na diferenciação entre o background e o movimento de pinça palmar, utilizando a combinação dos atributos temporais e espectrais; e acurácia de até 76% na distinção entre os movimentos de pinça de precisão e lateral, com uso de atributos espectrais.

Em termos de controle de um dispositivo externo, utilizando o neuroheadset EMOTIV EPOC e um Arduino MEGA2560 para realizar a leitura dos sinais provenientes de 14 eletrodos, Santos (2017), realizou experimentos para controlar um pendulo. O experimento foi realizado com cinco pessoas, e consistia em pensar em um movimento para que um pêndulo assumisse três posições: desligado, quando o usuário pensasse em um objeto parado; pêndulo em 45° quando pensasse em um objeto ligado, iniciando um movimento constante sem alta velocidade; pêndulo em 48°, quando o usuário pensar em um objeto ligado com velocidade duas vezes maior do que o pensamento para o angulo de 45°. O tempo de janela de gravação do pensamento foi de 20s para cada pensamento, sendo o pré-processamento e a classificação dos sinais feitos com uso do Matlab. Os dados

foram divididos em 70% para treinamento e 30% para validação, utilizando os seguintes algoritmos para classificação: Máquina de Aprendizado Extremo, K-NN, Árvore de decisão, SVM, Máquina de Vetor de Relevância e XgBoost, sendo este último o que apresentou melhor resultado de acurácia, 99,86%. Nesta aplicação, destaca-se o volume de dados devido à janela de 20s adotada, podendo este ser um problema computacional, implicando em um alto custo de processamento.

A interface cérebro máquina, também pode ajudar indivíduos com doenças degenerativas, e prolongar a independência destes a depender do nível da doença. No caso da esclerose lateral amiotrófica (ELA), o trabalho de Sellers, Vaughan e Wolpaw (2010), propôs uma interface, utilizando EEG, adquirido com uso de uma touca com oito eletrodos de fácil aplicação, e manutenção. Os testes foram realizados com uma voluntária de 51 anos, portadora de ELA, que anteriormente se comunicava com seus familiares com um dispositivo que utilizava os movimentos dos olhos, o que se tornou inviável com um tempo, devido à diminuição do movimento dos olhos da voluntária. Outro componente do dispositivo é um computador, onde o monitor expõe uma matriz, na qual são realizadas as escolhas de letras e/ou funções, esta escolha pode ser vista no EEG através do potencial P300, a partir deste potencial, o computador aplica um algoritmo de regressão múltipla que mostra qual item gerou o potencial P300 e realiza a seleção. O resultado dos testes, realizados por dois anos e meio, com uma estimativa de uso de 6h à 8h por dia, demonstrou um desempenho média de 83%, tendo sido utilizado para comunicação via e-mail, ligar e desligar dispositivos domésticos como luzes e TV, dentre outras funções. Vale ressaltar que a voluntária estava acompanhada de sua cuidadora durante o uso do dispositivo e que durante o tempo de uso, eram dados feedbacks periódicos aos desenvolvedores.

Outra abordagem que poderia ser implantada em um dispositivo como o citado no parágrafo anterior é a proposta por Ye et al. (2017), uma plataforma multitarefas, que utiliza sinais da imagética motora das mãos, onde a imagética da mão esquerda alterna entre as tarefas, e a da mão direita permite a seleção de uma tarefa. Neste caso, a coleta é dada por 27 eletrodos de EEG. Para o experimento, foram coletados dados de três voluntários. Os sinais obtidos foram pré-processados, com uso de 9 filtros passa-banda, de 4Hz a 40Hz, e para extração de atributos foi utilizado o método de *Common Spatial Pattern* (CSP). Para classificação foi utilizado

o algoritmo *Linear Discriminant Analysis* (LDA), que obteve uma acurácia média de 70%. Embora seja uma opção interessante, pelo fato de haver uma opção de confirmação por parte do voluntário, há de se considerar que esta abordagem um custo computacional maior, devido à etapa de pré-processamento, e a maior quantidade de dados coletados.

Embora os sinais de EEG sejam os mais utilizados nas Interfaces Cérebro Máquina, como dito anteriormente há outras técnicas que podem fornecer sinais a serem utilizados. O trabalho de Khalaf, Sejdic e Akcakaya (2019) apresenta uma proposta de Interface Cérebro Máquina, baseada na imagética motora, utilizando dados coletados de sinais de EEG e de doppler funcional transcraniano. Foram utilizados 16 canais para coleta do EEG e dois transdutores de 2MHZ, posicionados nos lados, esquerdo e direito, da janela temporal acima do arco zigomático. Foram coletados dados de 10 indivíduos, e o experimento de coleta consistiu em imaginar movimentos das pernas direita e esquerda, de acordo com setas horizontais apresentadas em uma tela, o tempo destinado a cada movimento foi de 10s. Como atributo para classificação foi extraído o espectro de energia de ambas as aquisições, utilizando o método de Welch, ao total, foram extraídos 420 atributos, 320 provenientes dos sinais de EEG, e 100 provenientes dos sinais dos transdutores. O algoritmo utilizado para classificação foi o *Support Vector Machine*, o método obteve 89,46%, como melhor resultado de acurácia, referente à diferenciação entre a imagética do braço esquerdo e o estado de repouso.

3.2 CONSIDERAÇÕES

Neste capítulo foram apresentados diversos métodos com o objetivo de classificar diferentes sinais cerebrais, chave para o desenvolvimento de Interfaces Cérebro Máquina eficientes e seguras. Segue na Tabela 7 abaixo o resumo dos trabalhos apresentados, e suas características principais.

Tabela 7 – Resumo dos trabalhos relacionados e suas principais características (continua...)

Trabalho	Proposta	Experimento	Métodos de Classificação
SAMUEL et al.,2017	Identificação de movimentos da imagética motora da mão, utilizando sinais de EEG, 64 canais, e atributos de tempo e frequência.	Imagética de sete movimentos de única mão.	LDA, SVM,MLP, Discriminante Linear de Fisher.
ZHANG et al.,2017	Classificação de sinais de EEG, provenientes de 6 eletrodos, tendo como atributos as combinações: coeficiente de autoregressão e entropia aproximada; decomposição de wavelet e coeficiente de autoregressão.	Execução de tarefas mentais.	SVM polinomial: 1-12, SVM Kernel RBF.
KAYIKCIOGLU; AYDEMIR, 2010	Proposta de classificação de dados de imagética motora para Interface Cérebro máquina, utilizando sinais de EEG, de 6 eletrodos, e coeficientes da função característica das curvas padrões dos movimentos, como atributo.	Movimento de um cursor, para cima e para baixo.	k-NN, SVM Kernel RBF, MLP.
ALAZRAI; ALWANNI; DAOUD, 2018	Identificação de movimentos dos dedos de uma mão, utilizando sinais de EEG, de 14 eletrodos, e distribuição de Choi-Willimas.	Movimentos dos dedos da mão direita.	Método de classificação com duas camadas.
JOCHUMSEN; KHAN; DREMSTRUP, 2015	Deteção e classificação de três movimentos diferentes de uma mesma mão, utilizando sinais de EEG de 25 canais, e atributo de tempo e frequência.	Três movimentos de pinça com uma mão.	LDA.
SANTOS, 2017	Proposta de Interface Cérebro Máquina para movimentação de dispositivo	Execução de tarefas mentais.	ELM, k-NN, SVM, RVM, XgBoost.


	externo, utilizando sinais de EEG, com 12 eletrodos, e amplitude dos sinais para diferenciação das tarefas.		
SELLERS; VAUGHAN; WOLPAW, 2010	Interface Cérebro Máquina para portadores de Esclerose Lateral Amiotrófica (ELA), utilizando sinais de EEG proveniente de touca com 8 eletrodos, e algoritmo de regressão múltipla para identificar P300.	Seleção de itens (letras e caracteres) em uma matriz.	-
YE et al., 2017	Sistema multitarefas, utilizando a imagética motora para seleção e confirmação de funções. Baseados em sinais de EEG, de 27 canais e extração de atributos com uso de CSP.	Imagética motora, mão esquerda e mão direita.	LDA
KHALAF; SEJDIC; AKCAKAYA, 2019	Interface Cérebro Máquina utilizando imagética motora e sinais de EEG, de 16 canais, combinados a Doppler Transcraniano funcional, com uso de 2 transdutores. Sinais caracterizados pelo espectro de energia.	Imagética motora, braço esquerdo e braço direito.	SVM

Fonte: A Autora (2019).

4 MATERIAIS E MÉTODOS

Este capítulo abordará o método utilizado para o desenvolvimento deste trabalho, o mesmo está esquematicamente representado na Figura 11, e cada etapa será discutida detalhadamente adiante.

Figura 11 - Desenho esquemático do método seguido neste estudo




Fonte: A Autora (2019).

4.1 AQUISIÇÃO DE SINAL E BASE DE DADOS

Para aquisição dos sinais foi utilizado o amplificador g.Hiamp da g.tec, com taxa de amostragem de 256Hz. A fim de evitar ruídos no sinal foram configurados no equipamento os filtros: Notch (60Hz) e um passa banda com limites de 0.5Hz e 30Hz. Foram utilizados 27 eletrodos, dispostos de acordo com a Figura 12, esta disposição abrange a área sensório motora, na qual se encontram as informações desejadas, além destes eletrodos, tem-se o posicionamento de um referencial preso ao lóbulo auricular direito.


Figura 12 - Posicionamento dos eletrodos



Fonte: g.tec (2016).


A base de dados é composta pelos sinais de EEG oriundos de cinco sessões, realizadas com o mesmo voluntário, vale ressaltar que o sujeito não possui nenhum tipo de déficit motor ou neurológico. Antes de iniciar-se a aquisição dos sinais, o voluntário foi posicionado confortavelmente em uma cadeira, frente a um monitor, com braços, mãos e pés relaxados e apoiados, neste momento foram dadas orientações para que a cada seta apresentada no monitor fosse imaginado um movimento com o membro correspondente, seguindo a relação: seta para direita – movimento imaginado com a mão direita, seta para esquerda – movimento imaginado com a mão esquerda, seta para cima – movimento imaginado com o pé; além disto, foram apresentadas as imagens das setas, individualmente, as mesmas podem ser visualizadas na Figura 13, abaixo.

Figura 13 - Setas indicativas do movimento a ser imaginado



Fonte: g.tec (2016).

Os testes aos quais o voluntário foi submetido eram compostos de 60 comandos aleatórios, divididos igualmente entre os três tipos de movimento, cada comando é parte de uma *trial* com duração de 8s, divididos conforme Figura 14, na qual pode-se observar que as setas são exibidas por um tempo inferior a 2s. O intervalo entre as *trials* também são aleatórios podendo variar de 0.5s a 2.5s.

Figura 14 - Esquema sequencial de uma *trial*

Fonte: g.tec (2016).

Em todas as sessões foram dadas as mesmas instruções ao voluntário, e solicitado que o movimento imaginado também fosse o mesmo.

4.2 SEGMENTAÇÃO DO SINAL

Para esta etapa foi utilizado o software GNU Octave, versão 4.0.3 (EATON et al., 2015). Os registros de cada sessão foram segmentados manualmente nas três classes de movimentos existentes, isto foi possível porque o software da g.tec disponibiliza a matriz com a aleatoriedade dos movimentos, uma das configurações pode ser observada na Figura 15. A janela utilizada foi de 8s, a fim de captar toda informação da *trial*, com isto, obteve-se registro das seguintes quantidades de movimentos imaginados: 100 referentes a mão direita, 98 referentes a mão esquerda e 100 referentes ao pé; a diferença obtida deve-se provavelmente a perdas durante o registro dos sinais, visto que o software exclui informações com ruídos significativos.

Figura 15 - Vetores aleatórios para cada um dos movimentos.

Mão direita	0	0	0	1	1	0	0	1	0	0	1	0	0	0	1	0	0	0	1	1	1	0	0	0	1	0	1	0	0
Mão esquerda	1	0	1	0	0	1	0	0	1	0	0	0	1	1	0	0	1	1	0	0	0	0	1	1	0	1	0	0	0
Pé	0	1	0	0	0	0	1	0	0	1	0	1	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	1	1

(a)

Mão direita	1	0	0	0	0	0	1	1	1	0	0	0	0	0	0	1	0	0	1	0	0	1	0	0	1	0	0	1
Mão esquerda	0	0	0	0	0	1	0	0	0	1	0	1	0	1	0	0	0	1	0	0	1	0	0	1	0	0	1	0
Pé	0	1	1	1	1	0	0	0	0	0	1	0	1	0	1	1	0	0	1	0	0	1	0	0	1	0	0	1

(b)


Fonte: A Autora (2019).

*Em (a) são apresentados os vetores para as 30 primeiras *trials* e (b) mostra as 30 finais.

4.3 PRÉ-PROCESSAMENTO E EXTRAÇÃO DE ATRIBUTOS

Considerando que a transformada de Wavelet possui boa resolução temporal e espacial, aplicou-se a mesma com sete níveis nos sinais segmentados, em seguida, para cada nível, foram calculados os seguintes parâmetros: Coeficiente, Desvio padrão, Energia, Entropia, Média, *Range* e *Skewness*. Esta etapa pode ser visualizada na Figura 16.

Figura 16 - Esquema da utilização da Transformada de Wavelet



Fonte: A Autora (2019).

Os atributos foram escolhidos devido ao uso e relevância em processamento digital de sinais (ACHARYA et al., 2018; LI; SUN, 2008; TRAKOOLWILAIWAN et al, 2017; YUAN et al., 2011), estando descritos na Tabela 8. No total, foram obtidos 56 atributos.

Tabela 8 - Expressões matemáticas para cada um dos atributos (continua...)

Atributo	Expressão matemática
Coeficiente (Y(k))	$Y(k) = \sum_{j=1}^n X(j) W_n^{(j-1)(k-1)}$ Para, $W_n = e^{(-2\pi i)/n}$
Desvio padrão (σ)	$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N A_i - \mu ^2}$ Onde, A: variável aleatória com N escalares

	μ : média.
Energia (E(x))	$E(x) = \sum_{n=-\infty}^{+\infty} x[n] ^2$
Entropia (E(S))	$E(S) = \sum_{i=1}^n -x[n] \log_2 x[n]$
Média (μ)	$\mu = \frac{1}{k} \sum_{n=1}^k x_n$
Range (range)	$range = \max(X) - \min(X)$
Skewness (s)	$s = \frac{E(x - \mu)^3}{\sigma^3}$

Fonte: A Autora (2019).

4.4 CLASSIFICAÇÃO

Na etapa de classificação foram utilizados os *softwares* Weka (Waikato Environment for Knowledge Analysis), versão 3.8.1 (FRANK; HALL; WITTEN, 2016), e GNU Octave, versão 4.0.3, onde o Weka foi aplicado nos testes com Bayes Net, Naive Bayes, MLP, SVM, J48, Random Forest e Random Tree e o Octave aplicado aos testes com ELM e mELM. Os parâmetros dos classificadores foram variados, conforme Tabela 9, e para cada configuração foram realizados trinta testes tipo validação cruzada com 10 *folds*.

Tabela 9 - Parâmetros utilizados para representar as imagens durante a etapa de classificação

Classificador	Configuração
Bayes Net	-
Naive Bayes	-
MLP	Neurônios da camada intermediária: a, 10, 50,100
	Taxa de aprendizagem: 0.3
	Momento: 0.2
	Iterações: 500
SVM	Kernel polinomial: expoente (E) -1 a 5
	Kernel RBF: γ = 0.01e 0.5
J48	-
Random Forest	Arvores: 10, 50 e 100
Random Tree	-
ELM	Kernel Sigmoid
mELM	Neurônios da camada intermediária: 100
	Kernel: dilatação e erosão

Fonte: A Autora (2019).

As métricas de saída consideradas para avaliação do desempenho de classificação foram: Acurácia, Kappa, Tempo de Treino e Erro médio absoluto; os

mesmos estão dispostos na Tabela 10. Foram também observadas as matrizes de confusão (Figura 17) das configurações com melhor e pior desempenhos.

Figura 17 - Exemplo de matriz de confusão

		VALOR VERDADEIRO (confirmado por análise)	
		Positivo	Negativo
VALOR PREVISTO (predito pelo teste)	Positivo	Verdadeiros Positivos	Falsos Positivos
	Negativo	Falsos Negativos	Verdadeiros Negativos

Fonte: A Autora (2019).

Tabela 10 - Métricas de avaliação do desempenho da classificação

Métrica	Definição
Acurácia	$AC = \frac{\text{Verdadeiros Positivos} + \text{Verdadeiros Negativos}}{\text{Total de previsões}}$
Kappa	$K = \frac{p_0 - p_e}{1 - p_e}$
Tempo de Treino	Duração do processo de treino, dado em segundos.
Erro médio absoluto	$EMA = \frac{1}{n} \sum_{i=1}^n f_i - y_i ^{**}$

Fonte: A Autora (2019).

* p_0 : taxa de aceitação relativa, p_e : taxa hipotética de aceitação.

** f_i : valor previsto, y_i : valor verdadeiro.

Ainda em se tratando de Kappa, o mesmo pode variar entre -1 e 1, sendo o desempenho avaliado de acordo com a Tabela 11, onde 1 indica total concordância.

Tabela 11 - Classificação de acordo com o coeficiente Kappa

Coeficiente Kappa	Desempenho
$k \leq 0,2$	Ruim
$0,2 < k \leq 0,4$	Regular
$0,4 < k \leq 0,8$	Bom
$0,8 < k \leq 1$	Excelente

Fonte: A Autora (2019).

5 RESULTADOS E DISCUSSÃO

Neste capítulo estão dispostos os resultados obtidos de acordo com a metodologia descrita anteriormente. Foi utilizada uma abordagem quantitativa, com os seguintes parâmetros selecionados para análise: acurácia, kappa, erro médio absoluto, e tempo de treino. Sendo estes escolhidos por representarem características importantes em uma interface cérebro-maquina: reprodutibilidade, bom tempo de resposta e confiabilidade.

Seguem nas Tabelas 12 e 13 os valores médios e desvios padrões dos resultados dos testes para todas as configurações utilizadas, estando em destaque os melhores e piores valores alcançados, além dos resultados obtidos pela Random Forest, que serão detalhados adiante.

Tabela 12 - Valores médios de acurácia e kappa

Classificador	Configuração	Acurácia		Kappa	
		Média	DP	Média	DP
Bayes Net	-	90,754	5,099	0,861	0,076
Naive Bayes	-	74,616	5,652	0,619	0,085
MLP	Neurônios da camada intermediária: a	99,284	1,699	0,989	0,025
	Neurônios da camada intermediária: 10	99,362	1,607	0,990	0,024
	Neurônios da camada intermediária: 50	99,161	1,783	0,987	0,027
	Neurônios da camada intermediária: 100	99,072	1,823	0,986	0,027
	Kernel Linear	96,900	3,164	0,953	0,047
SVM	Kernel Polinomial E=2	99,173	1,571	0,988	0,024
	Kernel Polinomial E=3	99,375	1,416	0,991	0,021
	Kernel Polinomial E=4	99,274	1,606	0,989	0,024
	Kernel Polinomial E=5	98,972	1,992	0,985	0,030
	RBF Kernel ($\gamma=0.01$)	75,670	5,806	0,635	0,087
	RBF Kernel ($\gamma=0.5$)	98,424	2,145	0,976	0,032
J48	-	94,531	4,388	0,918	0,066
Random Forest	Arvores: 10	98,085	2,756	0,971	0,041
	Arvores: 50	98,772	2,170	0,982	0,033
	Arvores: 100	98,837	2,033	0,983	0,031
Random Tree	-	94,946	4,547	0,924	0,068
ELM	Kernel Sigmoide	99,306	1,496	0,992	0,017
mELM	Kernel de dilatação	99,171	1,528	0,991	0,017
	Kernel de erosão	98,771	2,139	0,986	0,024

Fonte: A Autora (2019).

Tabela 13 - Valores médios e desvio padrão do erro médio absoluto e do tempo de treino

Classificador	Configuração	Erro médio absoluto		Tempo de treino	
		Média	DP	Média	DP
Bayes Net	-	0,062	0,032	0,019	0,025
Naive Bayes	-	0,170	0,037	0,005	0,002
MLP	Neurônios da camada intermediária: a	0,009	0,010	7,829	0,783
	Neurônios da camada intermediária: 10	0,009	0,009	2,801	0,037
	Neurônios da camada intermediária: 50	0,009	0,010	12,826	0,112
	Neurônios da camada intermediária: 100	0,009	0,010	25,445	0,231
SVM	Kernel Linear	0,229	0,007	0,053	0,019
	Kernel Polinomial E=2	0,224	0,004	0,082	0,030
	Kernel Polinomial E=3	0,224	0,003	0,085	0,025
	Kernel Polinomial E=4	0,225	0,005	0,084	0,018
	Kernel Polinomial E=5	0,225	0,006	0,088	0,023
	RBF Kernel ($\gamma=0.01$)	0,281	0,016	0,093	0,044
	RBF Kernel ($\gamma=0.5$)	0,226	0,005	0,060	0,014
J48	-	0,040	0,028	0,013	0,002
Random Forest	Arvores: 10	0,051	0,018	0,013	0,010
	Arvores: 50	0,051	0,014	0,057	0,012
	Arvores: 100	0,051	0,015	0,111	0,018
Random Tree	-	0,034	0,030	0,002	0,002
ELM	Kernel Sigmoide	0,723	0,030	0,006	0,012
mELM	Kernel de dilatação	0,009	0,003	0,009	0,015
	Kernel de erosão	0,009	0,001	0,008	0,015

Fonte: A Autora (2019).

Os classificadores bayesianos apresentaram resultados bastante divergentes, evidenciados pela acurácia, tendo o Naive Bayes uma acurácia de apenas 74,61%, e a Bayes Net um valor de 90,75%, esta divergência também pode ser observada no tempo de treino, sendo o tempo do Naive Bayes três vezes menor. Na Tabela 14, tem-se a matriz de confusão do resultado apresentado pelo Naive Bayes, que mostra erro de classificação em todas as classes, bastante visível na confusão entre os movimentos pé e mão direita, esse fenômeno pode ser atribuído a imprecisões quanto a representação da imagética do pé no córtex cerebral.

Tabela 14 - Matriz de confusão pior resultado de acurácia - Naive Bayes

		Mão direita	Mão esquerda	Pé
Pior resultado	Mão direita	90	10	0
	Mão esquerda	3	93	2
	Pé	56	5	39

Fonte: A Autora (2019).

Todas as configurações de MLP utilizadas mostraram resultados de acurácia superiores a 99% e valores de kappa acima de 0,9, ambos com desvios padrões satisfatórios, porém os mesmos detiveram os maiores tempos de treino, sendo o menor deles, atingido pela configuração com 10 camadas intermediárias, 2,80s, trinta e cinco vezes maior que o atingido pelo SVM de kernel polinomial 3, cujo valor de acurácia apresentado semelhante.

Em termos de acurácia o melhor resultado alcançado foi pela Máquina de Vetor de Suporte, com a configuração de kernel polinomial 3, com valor de 99,37%, seguido de outros bons resultados como kappa de 0,99, erro médio absoluto de 0,22, tempo de treino de 0,08s, evidenciados na matriz de confusão da Tabela 15. No geral todas as configurações de SVM obtiveram valores semelhantes de tempo de treino e acurácia, apenas a configuração com kernel RBF ($\gamma = 0,01$) apresentou um resultado de acurácia abaixo de 90%, acompanhado de um kappa de 0,63.

Tabela 15 - Matriz de confusão melhor resultado de acurácia - SVM

		Mão direita	Mão esquerda	Pé
Melhor resultado	Mão direita	100	0	0
	Mão esquerda	1	97	0
	Pé	0	0	100


Fonte: A Autora (2019).

As árvores de decisão tiveram também bom desempenho, todas com acurácia acima de 90%, sendo os melhores resultados obtidos pela Random Forest, com as configurações de 50 e 100 árvores, as acurácias das mesmas foram de 98,77% e 98,83%, respectivamente, merecendo destaque a diferença no tempo de treino, 0,05s para 50 árvores, e 0,11s para 100 árvores. A J48 e a Random Tree apresentaram valores de acurácia semelhantes, de aproximadamente 94%, sendo o menor tempo de 0,002s atribuído a Random Tree.

As máquinas de aprendizado extremo demonstraram uma performance promissora, com acurácias acima de 98%, e os melhores resultados do kappa e erro médio absoluto, sendo eles 0,992 o kappa para a ELM com kernel sigmoide, e um erro de 0,009 com desvio padrão de 0,001 para o kernel de erosão da ELM morfológica.

Nas Figuras 18 e 19, abaixo, pode-se visualizar melhor os resultados de acurácia e kappa obtidos por classificadores em suas melhores configurações. Quanto à acurácia observa-se que os classificadores que apresentaram melhores resultados médios foram os que também apresentaram menor dispersão, dentre os melhores resultados vale destacar a dispersão da Random Tree. Como esperado, vê-se também a maior dispersão no classificador que apresentou o pior resultado em termos de acurácia, o Naive Bayes.


Figura 18 - BoxPlot: Acurácia *versus* melhores configurações dos classificadores



Fonte: A Autora (2019).

Em se tratando de kappa, está ainda mais evidenciado o espalhamento para o pior classificador. Atenta-se para o fato de que a maior parte dos classificadores apresentou um nível de dispersão ainda que pequeno para o kappa, dentre eles todas as árvores de decisão.

Figura 19 - BoxPlot: Kappa versus melhores configurações dos classificadores



Fonte: A Autora (2019).

5.1 CONSIDERAÇÕES

Detentores dos melhores resultados de acurácia, a SVM e MLP, possuem uma característica semelhante o uso de hiperplano, com a principal diferença de que no MLP cada neurônio da camada intermediária produz um hiperplano próprio no espaço de decisão, sendo esta talvez a diferença crucial que causa a discrepância no tempo de treino, fazendo da SVM uma melhor escolha (HAYKIN, 2009).

Outro aspecto da SVM é a retirada de dados do treinamento para uso como vetor de suporte, que representa uma característica estável dos dados, este fato pode ser um dos indicativos do bom desempenho deste classificador, além de um fator promissor, visto que os padrões da imagética motora são intrínsecos aos indivíduos. Em contrapartida a SVM pode apresentar um problema computacional proporcional à dimensionalidade dos dados de entrada, que demandará um alto custo, e em certo ponto implicará em um problema de generalização, a depender da curva de separação ótima encontrada no hiperplano, neste caso apenas o custo computacional seria aplicado ao problema aqui estudado, devido à característica dos padrões anteriormente citada (HAYKIN, 2009) (LORENA; CARVALHO, 2007).

Considerando o tempo de treino, o algoritmo de Random Tree apresentou o melhor resultado, acompanhado de uma boa acurácia, possivelmente por sua característica de não ser necessário o preparo dos dados independente da

dimensão do problema (GEURTS; ERNST; WEHENKEL, 2006). Em se tratando de árvores de decisão, vale destacar o desempenho da Random Forest, com 50 árvores, apresentando uma acurácia de 98,77% obteve um tempo de treino ainda menor que todos os da SVM. Uma particularidade das árvores de decisão favorável ao problema estudado é o bom desempenho com problemas pouco generalizáveis. Ainda em se tratando de tempo de treino, todas as máquinas de aprendizado extremo apresentaram resultados em milissegundos, como esperado visto que utilizam um método analítico para determinar os pesos de saída (BREIMAN, 2001) (PAHWA; PAPREJA; MIGLANI, 2014) (CAMBRIA, 2013) (AZEVEDO et al., 2015).

Por fim o Naive Bayes foi o classificador com os piores resultados de acurácia e kappa obtidos, sendo este um classificador probabilístico tem como premissa a independência dos atributos entre si, podendo ser este um fator indicativo do seu baixo desempenho nos testes realizados, visto que os atributos utilizados para caracterizar o sinal têm relações diretas entre si (CHENG; GREINER, 2001).

Um resumo desses melhores e piores resultados é apresentado na Tabela 16.

Tabela 16 – Resumo dos resultados obtidos

Método	Acurácia	Kappa	Erro	Tempo de treino
MLP	↑	↑	↓	↑
SVM	↑	↑	↑	↑
mELM	↑	↑	↓	↓
ELM	↑	↑	↑	↓
Naive Bayes	↓	↓	↑	↓

Fonte: A Autora (2019).

6 CONCLUSÃO

As Interfaces Cérebro Máquina tem grande potencial para melhorar a qualidade de vida de diversas pessoas, porém, ainda existem grandes desafios: fisiológicos, ligados à compreensão de alguns mecanismos cerebrais; de processamento, relacionados à necessidade de uma resposta efetiva em tempo real; de custo, as aplicações a dispositivos externos, e interfaces, ainda estão bastante restrita a países desenvolvidos.

Desta forma, neste trabalho, foi utilizado para captação de sinais da imagética motora das mãos e do pé, o EEG, uma das técnicas mais difundidas de aquisição de sinal cerebral, que tem como vantagens: o baixo custo, quando relacionada a outras técnicas; a fácil aplicação, mesmo que haja a necessidade do uso do gel condutor, uma pessoa com um treinamento básico, é capaz de posiciona-los; e uma boa resolução temporal. Para caracterização dos padrões existentes nestes sinais de EEG, utilizou-se a Transformada Discreta de Wavelet, principalmente pela sua característica de ser adequada a sinais não estacionários, como é o caso dos sinais cerebrais, e os seguintes parâmetros: Coeficiente, Desvio padrão, Energia, Entropia, Média, Range, Skewness; que não demandam um alto custo computacional.

Para identificação de padrões da imagética motora das mãos e dos pés, realizaram-se experimentos nos quais foram utilizados os softwares gratuitos, e disponíveis na internet, Weka, versão 3.8.1, e GNU Octave, versão 4.0.3. Os algoritmos utilizados foram: Bayes Net, Naive Bayes, MLP, SVM, J48, Random Forest, Randon Tree, ELM e mELM.

Por fim, o método proposto foi capaz de diferenciar satisfatoriamente as três classes de movimentos da imagética analisados, este desempenho pode ser visto com os altos valores de acurácia alcançados, superiores a 99%, no caso do melhor resultado havendo apenas um erro de classificação. Consequentemente o método adotado, com o melhor classificador, pode vir a contribuir no avanço das técnicas aplicadas a Interfaces Cérebro Máquina.

6.1 LIMITAÇÕES

A principal dificuldade apresentada neste trabalho foi à utilização de sinais adquiridos de apenas um indivíduo. Este ponto é de extrema importância, visto que os padrões cerebrais, ainda que sejam oriundos das mesmas áreas, são variáveis entre os seres humanos. Vale ressaltar que além de serem variáveis, podem ser gerados por áreas diferentes do cérebro, devido à plasticidade citada anteriormente.

6.2 CONTRIBUIÇÕES

Os resultados obtidos demonstraram grande potencial e pode contribuir para a academia com a validação de um método computacional de baixo custo e eficiente para diferenciação de sinais da imagética motora, sendo este uma opção para estudos que envolvam o controle de interfaces. Como produto da contribuição, tem-se o capítulo “*An EEG brain-computer interface to classify motor imagery signals*”, publicado no livro intitulado “*Biomedical Signal Processing*” (Apêndice A).

6.3 TRABALHOS FUTUROS

Como trabalhos futuros, a fim de o método proposto de maneira mais ampla, recomenda-se a aplicação deste em sinais coletados de outros indivíduos, com diferentes perfis, incluindo indivíduos com limitações motoras em diversos estágios. Pode-se ainda aplicar este método na tentativa de diferenciação de padrões cerebrais de tarefas mentais, visto que as interfaces cérebro máquina não estão condicionadas ao uso de padrões da imagética motora, e necessitam da maior precisão e agilidade possível.

REFERÊNCIAS

- ACHARYA, U. R.; OH, S. L.; HAGIWARA, Y.; TAN, J. H.; ADELI, H. Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals. **Computers in Biology and Medicine**, v. 100, n. 1, p. 270-278, 2018.
- AL-TIMEMY, A. H.; BUGMANN, G.; ESCUDERO, J.; OUTRAM, N. A preliminary investigation of the effect of force variation for myoelectric control of hand prosthesis. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE*, 35., Osaka, 2013. **Proceedings [...]**. Osaka: IEEE, 2013. p. 5758–5761.
- AL-TIMEMY, A. H.; KHUSHABA, R. N.; BUGMANN, G.; ESCUDERO, J. Improving the performance against force variation of EMG controlled multifunctional upper-limb prostheses for transradial amputees. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 24, n. 6, p. 650–661, 2016.
- ALAZRAI, R.; ALWANNI, H.; DAOUD, M. I. EEG-based BCI system for decoding finger movements within the same hand. **Neuroscience Letters**, v. 698, p. 113–120, 2019.
- AZEVEDO, W. W.; LIMA, S. M.; FERNANDES, I. M.; ROCHA, A. D.; CORDEIRO, F. R.; SILVA-FILHO, A. G. da; SANTOS, W. P. dos. Fuzzy Morphological Extreme Learning Machines to detect and classify masses in mammograms. *In: IEEE INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS (FUZZ-IEEE)*, Istanbul, 2015. **Proceedings [...]**. Istanbul: IEEE, 2015. p. 1–8.
- BAUER, S. M.; ELSAESSER, L. J.; ARTHANAT, S. Assistive technology device classification based upon the World Health Organization's, International Classification of Functioning, Disability and Health (ICF). **Disability and Rehabilitation: Assistive Technology**, v. 6, n. 3, p. 243–259, 2011.
- BERGMEISTER, K. D.; HADER, M.; LEWIS, S.; RUSSOLD, M. F.; SCHIESTL, M.; MANZANO-SZALAI, K.; ROCHE, A. D.; SALMINGER, S.; DIETL, H.; ASZMANN, O. C. Prosthesis control with an implantable multichannel wireless electromyography system for high-level amputees: a large-animal study. **Plastic and reconstructive surgery**, v. 137, n. 1, p. 153–162, 2016.
- BORG, J.; LARSSON, S.; ÖSTERGREN, P.O. The right to assistive technology: For whom, for what, and by whom?. **Disability & Society**, v. 26, n. 2, p. 151–167, 2011.
- BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.
- CHENG, J.; GREINER, R. Learning Bayesian Belief Network Classifiers: Algorithms and System. *In: STROULIA, E.; MATWIN, S. (eds.) Advances in Artificial Intelligence*. Berlin: Springer, 2001. p. 141–151.
- CONTROZZI, M.; CLEMENTE, F.; BARONE, D.; GHIONZOLI, A.; CIPRIANI, C. The SSSA-MyHand: a dexterous lightweight myoelectric hand prosthesis. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 25, n. 5, p. 459–468, 2017.

- DALY, J. J.; WOLPAW, J. R.; CLEVELAND, L. S. Brain-computer interfaces in neurological rehabilitation. **The Lancet Neurology**, v. 7, n. 11, p. 1032–1043, 2008.
- DYSON, M.; BARNES, J.; NAZARPOUR, K. Myoelectric Control with Abstract Decoders. **Journal of Neural Engineering**, v. 15, n. 5, 2018.
- EATON, J. W.; BATEMAN, D.; HAUBERG, S.; WEHBRING, R. **GNU Octave manual: a high-level interactive language for numerical computations**. New York: Free Software Foundation, 2015.
- EIDE, A. H.; ØDERUD, T. Assistive technology in low-income countries. *In*: MACLACHLAN, M.; SWARTZ, L. (eds.) **Disability & International Development**. New York: Springer, 2009. p. 149–160.
- FRANK, E.; HALL, M. A.; WITTEN, I. H. The WEKA Workbench. *In*: KAUFMANN, M. (ed.) **Online appendix for data mining: practical machine learning tool and techniques**. 4. ed.. Cambridge, MA: Elsevier, 2016. Apêndice B. p. 553.
- GEURTS, P.; ERNST, D.; WEHENKEL, L. Extremely randomized trees. **Machine Learning**, v. 63, n. 1, p. 3–42, 2006.
- GHAZAEI, G.; ALAMEER, A.; DEGENAAR, P.; MORGAN, G.; NAZARPOUR, K. Deep learning-based artificial vision for grasp classification in myoelectric hands. **Journal of neural engineering**, v. 14, n. 3, p. 36 – 25, 2017.
- GUGER TECHNOLOGIES. **Common Spatial Patterns 3-class BCI**: Versão 2.16.00. Austria: g.tec, 2016.
- HAAS, L. Hans Berger (1873-1941), Richard Caton (1842-1926), and electroencephalography. **Journal of Neurology, Neurosurgery, and Psychiatry**, v. 74, n. 1, p. 9. Disponível em: doi: 10.1136/jnnp.74.1.9, 2003. Acesso em: 15/05/2019.
- HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. Canadá: Pearson, 2009.
- ISON, M.; ARTEMIADIS, P. The role of muscle synergies in myoelectric control: trends and challenges for simultaneous multifunction control. **Journal of Neural Engineering**, v. 11, n. 5, 2014.
- JIANG, F.; JIANG, Y.; ZHI, H.; DONG, Y.; LI, H.; MA, S.; WANG, Y.; DONG, Q.; SHEN, H.; WANG, Y. Artificial intelligence in healthcare: past , present and future. **Stroke Vascular Neurology**, v. 2, n. 4, p. 230-243. Disponível em: doi: 10.1136/svn-2017-000101, 2017. Acesso em: 03/05/2019.
- JOCHUMSEN, M.; KHAN, I.; DREMSTRUP, K. Detecting and classifying three different hand movement types through electroencephalography recordings for neurorehabilitation. **Medical & Biological Engineering & Computing**, v. 54, n. 10, p. 1491-1501, 2015.
- KANDEL, E. R.; SCHWARTZ, J. H.; JESSELL, T. M.; SIEGELBAUM, S. A.; HUDSPETH, A. J. **Princípios de Neurociência**. 5. ed. Porto Alegre: AMGH, 2014.

KAYIKCIOGLU, T.; AYDEMIR, O. A polynomial fitting and k -NN based approach for improving classification of motor imagery BCI data. **Pattern Recognition Letters**, v. 31, n. 11, p. 1207–1215, 2010.

KHALAF, A.; SEJDIC, E.; AKCAKAYA, M. A novel motor imagery hybrid brain computer interface using EEG and functional transcranial Doppler ultrasound. **Journal of Neuroscience Methods**, v. 313, n. 1, p. 44–53, 2019.

KHUSHABA, R. N.; AL-TIMEMY, A.; KODAGODA, S.; NAZARPOUR, K. Combined influence of forearm orientation and muscular contraction on EMG pattern recognition. **Expert Systems with Applications**, v. 61, p. 154–161, 2016.

KHUSHABA, R. N.; KRASOULIS, A.; AL-JUMAILY, A.; NAZARPOUR, K. Spatio-Temporal Inertial Measurements Feature Extraction Improves Hand Movement Pattern Recognition without Electromyography. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 40th, Honolulu, 2018. Proceedings [...]*. Honolulu, HI, p. 2108–2111, 2018.

LI, J.; SUN, S. Energy feature extraction of EEG signals and a case study. *In: IEEE INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS; IEEE WORLD CONGRESS ON COMPUTATIONAL INTELLIGENCE, Hong Kong, 2008. Proceedings [...]*. Hong Kong: IEEE, 2008. p. 2366–2370.

LIU, J. Feature dimensionality reduction for myoelectric pattern recognition: A comparison study of feature selection and feature projection methods. **Medical Engineering & Physics**, v. 36, n. 12, p. 1716–1720, 2014.

LORENA, A. C.; CARVALHO, A. C. P. L. F. DE. Uma Introdução às Support Vector Machines. **Revista de Informática Teórica e Aplicada**, v. 14, n. 2, 2007.

MARTIN, S.; KELLY, G.; KERNOHAN, W. G.; MCCREIGHT, B.; NUGENT, C. Smart home technologies for health and social care support. **Cochrane Database of Systematic Reviews**, v. 4, n. 2, 2008.

MILLÁN, J.d.R.; RUPP, R.; MÜLLER-PUTZ, G.; MURRAY-SMITH, R.; GIUGLIEMMA, C.; TANGERMANN, M.; VIDAURRE, C.; CINCOTTI, F.; KUBLER, A.; LEEB, R. Combining brain–computer interfaces and assistive technologies: state-of-the-art and challenges. **Frontiers in Neuroscience**, v. 4, p. 161, 2010.

ORGANIZAÇÃO MUNDIAL DE SAÚDE. **Relatório mundial de envelhecimento e saúde**. Genebra: OMS, 2015.

PAHWA, P.; PAPREJA, M.; MIGLANI, R. Performance Analysis of Classification Algorithms. **International Journal of Computer Science and Mobile Computing**, v. 3, n. 4, p. 50–58, 2014.

PURVES, D.; AUGUSTINE, G. J.; FITZPATRICK, D.; AL, E. **Neuroscience**. 4. ed., Massachusetts: Sinauer Associates, 2004.

RUSSELL, S.; NORVIG, P. **Inteligência Artificial**. 3. ed., Rio de Janeiro: Elsevier, 2013.

SAHA, S.; MAMUN, K. A.; AHMED, K.; MOSTAFA, R.; NAIK, G. R.; KHANDOKER, A.; DARVISHI, S.; BAUMERT, M. Progress in Brain Computer Interfaces: Challenges and Trends. **Computing Research Repository**, v. abs/1901.034442, 2019.

SAMUEL, O. W.; GENG, Y.; LI, X.; LI, G. Towards efficient decoding of multiple classes of motor imagery limb movements based on EEG spectral and time domain descriptors. **Journal of Medical Systems**, v. 41, n. 12, p. 194. Disponível em: doi: 10.1007/s10916-017-0843-z, 2017. Acesso em: 22/03/2019.

SANTOS, A. R. **Abordagens de aprendizado de máquina aplicadas à classificação de dados provenientes de equipamento eletroencefalográfico não-invasivo**. 2017. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Paraná, Curitiba, 2017.

SCHEME, E.; ENGLEHART, K. Electromyogram pattern recognition for control of powered upperlimb prostheses: state of the art and challenges for clinical use. **Journal of Rehabilitation Research & Development**, v. 48, n. 6, 2011.

SCHERER, M. J. Assessing the benefits of using assistive technologies and other supports for thinking, remembering and learning. **Disability and rehabilitation**, v. 27, n. 13, p. 731–739, 2005.

SCHERER, M. J.; GLUECKAUF, R. Assessing the benefits of assistive technologies for activities and participation. **Rehabilitation Psychology**, v. 50, n. 2, p. 132, 2005.

SELLERS, E. W.; VAUGHAN, T. M.; WOLPAW, J. R. A brain-computer interface for long-term independent home use. **Amyotrophic lateral sclerosis: official publication of the World Federation of Neurology Research Group on Motor Neuron Diseases**, v. 11, n. 5, p. 449–455. Disponível em: doi: 10.3109/17482961003777470, 2010. Acesso em: 20/02/2019.

TRAKOOLWILAIWAN, T.; BEHBOODI, B.; LEE, J.; KIM, K.; CHOI, J. W. Convolutional neural network for high-accuracy functional near-infrared spectroscopy in a brain-computer interface: threeclass classification of rest, right-, and left-hand motor execution. **Neurophotonics**, v. 5, n. 1, p. 5–15, 2017.

WORLD HEALTH ORGANIZATION. **International Classification of Functioning, Disability, and Health: Children & Youth Version: ICF-CY**. Geneva: WHO, 2007.

YE, Y.; YANG, C.; LI, X.; JU, Z.; LI, Z. The Design of Multi-task Simulation Manipulator Based on Motor Imagery EEG. *In: IEEE INTERNATIONAL CONFERENCE ON SYSTEMS, MAN, AND CYBERNETICS*, Canadá, 2017. **Proceedings [...]**. Canadá: SMC, 2017. p. 3284-3289.

YUAN, Q.; ZHOU, W.; LI, S.; CAI, D. Epileptic EEG classification based on extreme learning machine and nonlinear features. **Epilepsy Research**, v. 96, n. 1, p. 29–38, 2011.

ZANDER, T. O.; KOTHE, C. Towards passive brain-computer interfaces: applying brain-computer interface technology to human-machine systems in general. **Journal of Neural Engineering**, v. 8, n. 2, 2011.

ZHANG, Y.; LIU, B.; JI, X.; HUANG, D. Classification of EEG Signals Based on Autoregressive Model and Wavelet Packet Decomposition. **Neural Processing Letters**, v. 45, n. 2, p. 365-378, 2017.

APÊNDICE A - An EEG brain-computer interface to classify motor imagery signals

An EEG brain-computer interface to classify motor imagery signals

Maria Karoline Andrade, Maíra Araújo de Santana, Giselle Moreno, Igor Oliveira, Jhonnatan Santos, Marcelo Cairrão Araújo Rodrigues, and Wellington Pinheiro dos Santos

Abstract Considering the increase of life expectancy, people started to invest in technologies capable of improving the quality of life. One of these technologies is the Brain-Machine Interface. Combined to EEG signals, this technique may allow individuals with some motor disabilities to perform activities of daily living. Motor Imagery came up as an important tool to support this population. So they may send commands to external devices by using their brain voluntary activity. In this chapter the performance of an Imagery EEG-based BCI engine was accessed by applying Wavelet transform to the signals and extracting metrics used to describe digital signals. We used signals from the motor imagery of the right hand, left hand and foot movements. Different intelligent classifiers were tested. We achieved results greater than 99% of accuracy and Kappa above 0.99. The method is promising and can be used for future evaluations with several individuals to verify reproducibility.

1 Introduction and Motivation

According to World Health Organization (WHO), more than 2 billion people will need at least one assistive device until 2030. This estimation duplicates for the elderly [47, 69, 12, 68, 9, 54, 24]. WHO also points out that nowadays only one in each 10 poor people may have access to this kind of technology. That is due to the high costs associated to this technology and the lack of awareness about the use of the devices [47, 69, 12, 68, 9, 54, 24]. Despite these numbers, the development of new technologies is increasing year by year. These innovations aim to improve the quality of life of people with all kinds of disabilities.

Maria Karoline Andrade, Maíra Araújo de Santana, Giselle Moreno, Igor Oliveira, Jhonnatan Santos, Marcelo Cairrão Araújo Rodrigues, and Wellington Pinheiro dos Santos

Universidade Federal de Pernambuco, Recife, Brazil, e-mail:

{wellington.santos,karoline.andrade}@ufpe.br