



UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ARTES, CIÊNCIAS E HUMANIDADES
PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS DE INFORMAÇÃO

WALLACE FAVERON DE ALMEIDA

**Técnicas de aprendizado de máquina para interfaces cérebro-computador
baseadas em EEG**

São Paulo

2021

WALLACE FAVERON DE ALMEIDA

**Técnicas de aprendizado de máquina para interfaces cérebro-computador
baseadas em EEG**

Dissertação apresentada à Escola de Artes, Ciências e Humanidades da Universidade de São Paulo para obtenção do título de Mestre em Ciências pelo Programa de Pós-graduação em Sistemas de Informação.

Área de concentração: Metodologia e Técnicas da Computação

Versão corrigida contendo as alterações solicitadas pela comissão julgadora em 22 de abril de 2021. A versão original encontra-se em acervo reservado na Biblioteca da EACH-USP e na Biblioteca Digital de Teses e Dissertações da USP (BDTD), de acordo com a Resolução CoPGr 6018, de 13 de outubro de 2011.

Orientador: Prof. Dr. Clodoaldo Aparecido de Moraes Lima

São Paulo

2021

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

CATALOGAÇÃO-NA-PUBLICAÇÃO

(Universidade de São Paulo. Escola de Artes, Ciências e Humanidades. Biblioteca)

CRB 8 - 4936

Almeida, Wallace Faveron de

Técnicas de aprendizado de máquina para interfaces cérebro-computador baseadas em EEG / Wallace Faveron de Almeida ; orientador, Clodoaldo Aparecido de Moraes Lima. – 2021.

84 f : il.

Dissertação (Mestrado em Ciências) - Programa de Pós-Graduação em Sistemas de Informação, Escola de Artes, Ciências e Humanidades, Universidade de São Paulo, São Paulo.

Versão corrigida

1. Inteligência artificial. 2. Redes neurais. 3. Aprendizado computacional. 4. Eletroencefalografia. I. Lima, Clodoaldo Aparecido de Moraes, orient. II. Título

CDD 22.ed.– 006.3

Dissertação de autoria de Wallace Faveron de Almeida, sob o título “**Técnicas de aprendizado de máquina para interfaces cérebro-computador baseadas em EEG**”, apresentada à Escola de Artes, Ciências e Humanidades da Universidade de São Paulo, para obtenção do título de Mestre em Ciências pelo Programa de Pós-graduação em Sistemas de Informação, na área de concentração Metodologia e Técnicas da Computação, aprovada em 22 de abril de 2021 pela comissão julgadora constituída pelos doutores:

Prof. Dr. Clodoaldo Aparecido de Moraes Lima
Universidade de São Paulo
Presidente

Prof. Dr. Carlos Julio Tierra Criollo
Universidade Federal do Rio de Janeiro

Prof. Dr. Teodiano Freire Bastos Filho
Universidade Federal do Espírito Santo

Prof. Dr. João Paulo Papa
Universidade Estadual Paulista

Dedico este trabalho à minha família, que incentivou a minha educação e me apoiou para que eu pudesse concluir mais uma etapa.

Agradecimentos

Agradeço a Deus por ter me concedido inúmeras bênçãos e oportunidades ao longo da minha vida e por estar presente em todos os momentos de dificuldade nesta trajetória. Ele me deu forças para que pudesse superá-los e alcançasse meus sonhos e objetivos, como ser aprovado em diferentes processos seletivos, desde o ingresso em escola técnica para cursar o Ensino Médio até o vestibular da USP, e em seguida a pós-graduação. Em todo este período, nunca estive sozinho.

À minha família, minha profunda gratidão por ter me concedido um lar e por oferecer condições de concluir as primeiras etapas dos meus estudos. Em especial a minha mãe, Meire, ao meu pai, Wagner, e ao meu irmão, Wesley. Mesmo diante de muitos desafios e dificuldades, considero-me um privilegiado. Sem eles, não teria condições de ter chegado até aqui.

Ao meu orientador, Prof. Dr. Clodoaldo Aparecido de Moraes Lima, sou imensamente grato por ter aceito a tarefa de me orientar e guiar meus passos nesta jornada com alto nível de exigência. Foi uma grande honra de ter sido seu orientando. Obrigado por todos os ensinamentos, pelo tempo investido, pela paciência comigo, e por todos os papos, sejam em reuniões com ou sem hora marcada.

Agradeço também a Profa. Dra. Sarajane Marques Peres, por todo tempo e dedicação no apoio ao nosso projeto, além da participação ainda mais intensa como co-autora em uma de nossas publicações. Todas as dicas e provocações trouxeram muitas contribuições ao rigor e qualidade deste trabalho.

À minha noiva, Cristiana de Siqueira Silva Santos, todo o meu carinho e agradecimento por estar ao meu lado, me dar motivação, encarar todas as minhas maluquices, e também por ser compreensiva em todas as noites e finais de semana que estive dedicado a este projeto, e, por consequência, passamos menos tempo juntos.

Por fim, meu muito obrigado a todos os meus professores ao longo da vida, aos amigos e aos colegas de pesquisa, em particular ao Jonnathann, que me apoiaram e também mostraram caminhos a seguir. E aos meus colegas de trabalho, meus sinceros agradecimentos pelas palavras de incentivo e por ouvirem sobre minha pesquisa durante nosso expediente e como conciliar essas atividades com a minha rotina profissional.

Resumo

ALMEIDA, Wallace Faveron de. **Técnicas de aprendizado de máquina para interfaces cérebro-computador baseadas em EEG**. 2021. 84 f. Dissertação (Mestrado em Ciências) – Escola de Artes, Ciências e Humanidades, Universidade de São Paulo, São Paulo, 2021.

Pessoas que sofrem de doenças neurológicas podem apresentar algum tipo de paralisia e serem incapazes de realizar quaisquer funções motoras, mas podem ter algumas habilidades cognitivas. Neste caso, a única maneira de se comunicarem com o ambiente é usando suas atividades cerebrais. Sinais elétricos oriundos de diferentes partes do corpo humano podem ser usados como sinais de comando para controlar sistemas mecânicos. No entanto, é necessário que o responsável pelo controle de tais dispositivos seja capaz de gerar intencionalmente esses sinais, e que a interface adotada possa "entender" e processar tais sinais, definindo o comando adequado ao desejo do indivíduo. O sinal de eletroencefalograma (EEG) corresponde ao potencial elétrico devido à atividade cerebral e pode ser adquirido sobre o couro cabeludo. Interface Cérebro-Computador (BCI) consiste de um sistema capaz de traduzir a atividade neural do cérebro em comandos para dispositivos externos. Os principais fatores que influenciam o desempenho de um sistema de BCI são os sinais cerebrais capturados, os métodos de processamento, a extração de características, os algoritmos que traduzem essas características em comandos, os dispositivos de saída que executam esses comandos, a realimentação fornecida pelo usuário e as particularidades do usuário. A maioria dos sistemas de BCI contém, como parte principal, um algoritmo de aprendizado de máquina, que aprende a partir dos dados de treinamento uma função que pode ser usada para discriminar diferentes padrões de atividade cerebral. Por simplicidade, os algoritmos de aprendizado de máquina geralmente são divididos em dois módulos: extratores de características e classificadores. O módulo de extração remove as informações desnecessárias do sinal de entrada, e ao mesmo tempo retém informações que são importantes para discriminar diferentes classes de sinais. As características extraídas são traduzidas em um sinal de controle pelos algoritmos de aprendizado de máquina. Devido ao fato da tecnologia por trás de um sistema de BCI ainda não estar suficientemente madura e apresentar deficiências em aplicações de mundo real, a principal motivação desta Dissertação de Mestrado é realizar um estudo aprofundado envolvendo diversas técnicas de extração de características e classificadores visando classificar quatro diferentes tarefas de imagética motora (mão esquerda, mão direita, pés e língua). Os experimentos foram realizados utilizando uma base de dados de uma competição de BCI disponível publicamente. Com base nos experimentos realizados, pode-se afirmar que dentre os extratores de características utilizados, o Padrão Espacial Comum (CSP) foi aquele que extraiu as características mais discriminantes. Por outro lado, o intervalo de tempo usado para realizar a extração de característica apresentou pouca interferência no desempenho de classificação e os classificadores Máquina de Vetores Suporte (SVM), Perceptron Multicamadas (MLP) e Floresta de Caminhos Ótimos (OPF) apresentaram desempenho similares. Adicionalmente, as Redes Neurais Convolucionais (CNN), que não utilizam características geradas manualmente, também apresentaram performances semelhante em suas abordagens.

Palavras-chaves: Interface cérebro-computador. Imagética motora. Eletroencefalograma. Aprendizado de máquina. Extração de características. Classificação.

Abstract

ALMEIDA, Wallace Faverson de. **Machine learning techniques for EEG-based brain-computer interfaces**. 2021. 84 p. Dissertation (Master of Science) – School of Arts, Sciences and Humanities, University of São Paulo, São Paulo, 2021.

People who suffer from neurological diseases may have some form of paralysis and be unable to perform any motor functions, but they may have some cognitive skills. In this case, the only way to communicate with the environment is to use their brain activities. Electrical signals from different parts of the human body can be used as command signals to control mechanical systems. However, it is necessary that the person responsible for the control of such devices be able to intentionally generate these signals, and that the adopted interface can "understand" and process such signals, defining the command that best adapts to the individual's desire. The electroencephalogram (EEG) signal corresponds to the electrical potential due to brain activity and can be acquired on the scalp. Brain-Computer Interface (BCI) consists of a system capable of translating the brain's neural activity into commands for external devices. The main factors that influence the performance of a BCI system are the captured of the brain signals, the signal processing methods, the feature extraction methods, the algorithms that translate those characteristics into device commands, the output devices that execute these commands, the feedback provided by the user and the characteristics of the user. Most BCI systems contain, as a main part, a machine learning algorithm, which learns from the training data a function that can be used to discriminate different patterns of brain activity. For simplicity, machine learning algorithms are generally divided into two modules: feature extractors and classifiers. The extraction module removes unnecessary information from the input signal, while retaining information that is important for discriminating different classes of signals. The features extracted are translated into a control signal by the machine learning algorithms. Due to the fact that the technology behind a BCI system is not yet mature enough and has deficiencies in real-world applications, the main motivation of this Master Dissertation is to carry out an in-depth study involving several techniques for feature extraction and classifiers in order to classify four different motor imagery tasks (left hand, right hand, both feet and tongue). The experiments were carried out using a publicly available BCI competition database. Based on the experiments carried out, it can be said that among the feature extractors used, the Common Spatial Pattern (CSP) was the one that extracted the most discriminating features. On the other hand, the time interval used to perform the feature extraction showed little interference in the classification performance, and the Support Vector Machine (SVM), Multilayer Perceptron (MLP) and Optimum Path Forest (OPF) classifiers showed similar performance. Additionally, Convolutional Neural Networks (CNN), which do not use handcrafted features, also showed similar performances in their approaches.

Keywords: Brain-computer interface. Motor imagery. Electroencephalogram. Feature extraction. Machine learning. Classification.

Lista de figuras

Figura 1 – Representação de um segmento de sinal de EEG	20
Figura 2 – Distribuição dos eletrodos no couro cabeludo pelo sistema internacional 10-20 (A,B) e 10-20 estendido (C)	22
Figura 3 – Modelo de BCI baseado em sinais de EEG	25
Figura 4 – Comparativo entre registros de fMRI de imagéticas motoras (azul) e movimento real (roxo) para a tarefa relacionada aos membros superiores	29
Figura 5 – Manifestação dos ativação em cada hemisfério para MI das mãos es- querda (A) e direita (B)	30
Figura 6 – Decomposição wavelet em 5 níveis para um sinal de EEG	37
Figura 7 – Representação de um neurônio do tipo Perceptron	41
Figura 8 – Rede Neural do tipo MLP	42
Figura 9 – Conjunto linearmente separável	45
Figura 10 – Hiperplano ótimo e seus hiperplanos suporte	45
Figura 11 – Grafo completo	49
Figura 12 – Árvore de custo mínimo para a figura 11	49
Figura 13 – Protótipos selecionados da figura 12	49
Figura 14 – Floresta de caminhos ótimos gerados no treinamento da figura 11	50
Figura 15 – Teste de uma nova instância para classificação	50
Figura 16 – Amostra classificada pela função de conectividade da figura 11	50
Figura 17 – Exemplo de uma Rede Neural Convolutiva	52
Figura 18 – Exemplo de convolução discreta em duas dimensões	52
Figura 19 – Exemplo de uma Rede Neural antes (a) e após aplicação de <i>dropout</i> (b)	53
Figura 20 – Exemplo de operação de subamostragem usando o operador máximo . .	54
Figura 21 – Disposição dos eventos em cada ensaio do conjunto de dados	57
Figura 22 – Abordagem #1 para classificação do sinal de EEG	58
Figura 23 – Abordagem #2 para classificação do sinal de EEG	58
Figura 24 – Abordagem #1 para classificação do sinal de EEG com CNN	59
Figura 25 – Abordagem #2 para classificação do sinal de EEG com CNN	59
Figura 26 – Janela deslizante sobre o sinal de EEG e criação de <i>crops</i>	60
Figura 27 – Modelos implementado para CNN4	61

Figura 28 – Convolução em duas etapas: temporal e espacial	61
Figura 29 – Melhores resultados: indivíduo x classificador	70
Figura 30 – Melhores resultados: indivíduo x característica	71

Lista de tabelas

Tabela 1 – Diferentes faixas de frequência dos sinais de EEG	21
Tabela 2 – Sub-bandas de frequência para decomposição wavelet em 5 níveis	37
Tabela 3 – Estrutura dos modelos de CNN	62
Tabela 4 – Quantidade de parâmetros nos modelos de CNN	62
Tabela 5 – Resultados utilizando o classificador SVM - abordagem #1	64
Tabela 6 – Resultados utilizando o classificador MLP - abordagem #1	64
Tabela 7 – Resultados utilizando o classificador OPF - abordagem #1	64
Tabela 8 – Resultados utilizando o classificador SVM - abordagem #2 - variação 1	65
Tabela 9 – Resultados utilizando o classificador MLP - abordagem #2 - variação 1	66
Tabela 10 – Resultados utilizando o classificador OPF - abordagem #2 - variação 1	66
Tabela 11 – Resultados utilizando o classificador SVM - abordagem #2 - variação 2	66
Tabela 12 – Resultados utilizando o classificador MLP - abordagem #2 - variação 2	67
Tabela 13 – Resultados utilizando o classificador OPF - abordagem #2 - variação 2	67
Tabela 14 – Resultados utilizando o classificador SVM - abordagem #2 - variação 3	68
Tabela 15 – Resultados utilizando o classificador MLP - abordagem #2 - variação 3	68
Tabela 16 – Resultados utilizando o classificador OPF - abordagem #2 - variação 3	68
Tabela 17 – Resultados utilizando CNNs com 4 faixas - abordagem 1	69
Tabela 18 – Resultados utilizando CNNs - abordagem 2	69
Tabela 19 – Resultados utilizando CNNs com <i>crops</i> - abordagem 3	70
Tabela 20 – Matriz de confusão para os melhores resultados MLP	72
Tabela 21 – Matriz de confusão para os melhores resultados CNN	72
Tabela 22 – Comparação de resultados para o conjunto de dados BCI IV - 2a	73
Tabela 23 – Representação canônica da string de busca	82

Lista de abreviaturas e siglas

ANN	<i>Artificial Neural Network</i>
BCI	<i>Brain-Computer Interface</i>
CNN	<i>Convolutional Neural Network</i>
CSP	<i>Common Spatial Pattern</i>
CWT	<i>Continuous Wavelet Transform</i>
DL	<i>Deep Learning</i>
DWT	<i>Discrete Wavelet Transform</i>
EEG	Eletroencefalograma
ELU	<i>Exponential linear unit</i>
EMD	<i>Empirical Mode Decomposition</i>
EMG	Eletromiograma
ERD	<i>Event-Related Desynchronization</i>
ERM	<i>Empirical Risk Minimization</i>
ERP	<i>Event-Related Potential</i>
ERS	<i>Event-Related Synchronization</i>
fMRI	<i>functional Magnetic Resonance Imaging</i>
IAV	<i>Integrated Absolute Value</i>
IMF	<i>Intrinsic Mode Function</i>
LCD	<i>Local Characteristic-scale Decomposition</i>
MI	<i>Motor Imagery</i>
MLP	<i>Multilayer Perceptron</i>
MST	<i>Minimum Spanning Tree</i>

NIRS	<i>Near-infrared Spectroscopy</i>
OPF	<i>Optimum Path Forest</i>
OPT	<i>Optimum Path Tree</i>
ReLU	<i>Rectified Linear Unit</i>
RBF	<i>Radial Base Function</i>
RMS	<i>Root Mean Square</i>
SCP	<i>Slow Cortical Potential</i>
SMR	<i>Sensorimotor Rhythm</i>
SNR	<i>Signal-to-Noise Ratio</i>
SRM	<i>Structural Risk Minimization</i>
SSVEP	<i>Steady-State Visual Evoked Potential</i>
STFT	<i>Short-Time Fourier Transform</i>
SVM	<i>Support Vector Machines</i>
VEP	<i>Visual Evoked Potential</i>
WT	<i>Wavelet transforms</i>

Sumário

1	Introdução	15
1.1	<i>Definição do problema</i>	17
1.2	<i>Hipóteses</i>	17
1.3	<i>Objetivos</i>	17
1.4	<i>Método de pesquisa</i>	18
1.5	<i>Estrutura do documento</i>	19
2	Fundamentos e referencial teórico	20
2.1	<i>Eletroencefalograma (EEG)</i>	20
2.1.1	Tipos de oscilações neurais	21
2.1.2	Disposição dos eletrodos e o sistema internacional 10-20	22
2.1.3	Aplicabilidade dos sinais de EEG	23
2.2	<i>Interfaces cérebro-computador</i>	24
2.2.1	Sistemas de BCI baseados em EEG e seus componentes	25
2.2.2	Sinais de controle	26
2.2.3	Tipos de sistema	27
2.2.4	Ritmos sensório motor e imagéticas motoras	28
3	Processamento do sinal de EEG	31
3.1	<i>Técnicas de extração de características</i>	31
3.1.1	Padrões Espaciais Comuns	32
3.1.2	Dimensão Fractal - Katz e Higuchi	34
3.1.3	Transformada Discreta de Wavelet	35
3.1.4	Decomposição de Modo Empírico	37
3.1.5	Expoentes de Lyapunov	39
3.2	<i>Algoritmos tradicionais de aprendizado de máquina</i>	39
3.2.1	Redes Neurais Artificiais	40
3.2.2	Máquinas de Vetores Suporte	44
3.2.3	Floresta de Caminhos Ótimos	47
4	Aprendizado profundo para classificação de sinais de EEG	51

4.1	<i>Redes Neurais Convolucionais</i>	51
4.1.1	Camada de convolução	52
4.1.2	Camada de subamostragem	54
4.1.3	Camada de classificação - camada totalmente conectada	54
4.2	<i>Representação de um sinal 1D em 2D</i>	55
5	Experimentos e resultados	56
5.1	<i>Conjunto de dados</i>	56
5.2	<i>Etapas de pré-processamento e estratégias de treinamento</i>	57
5.3	<i>Configuração dos experimentos</i>	60
5.4	<i>Resultados</i>	62
6	Conclusão e trabalhos futuros	74
	REFERÊNCIAS	76
	Apêndice A – Protocolo do mapeamento sistemático	82

1 Introdução

Nos últimos anos, abordagens de pesquisa com o objetivo de desenvolver tecnologia para evoluir o potencial humano a partir da combinação entre a inteligência humana e a inteligência artificial têm recebido mais interesse da comunidade científica. A capacidade de usar cooperativamente os dois tipos de inteligência, fornecendo interfaces adequadas que permitirão ao cérebro humano se comunicar sem obstrução com um programa de computador e vice-versa, abrirá novas oportunidades de pesquisa. As interfaces cérebro-computador (do inglês *Brain-Computer Interfaces* - BCI) combinam conhecimentos e técnicas da neurociência e da inteligência artificial. É um tópico de pesquisa interessante e altamente interdisciplinar na interface entre medicina, psicologia, neurologia, processamento de sinais e aprendizado de máquina (SUN; ZHOU, 2014).

Pelo fato de possibilitar o controle do computador sem qualquer movimento físico, as BCIs apresentam potencial para revolucionar muitas áreas de aplicações, principalmente ao permitir que usuários comandem os dispositivos mais diversos, desde sistemas mais simples de entradas de texto até interfaces mais sofisticadas e adaptáveis, capazes de reagir aos estados mentais do usuário (LOTTE *et al.*, 2018).

Os sinais de eletroencefalograma (EEG) têm sido utilizados para monitorar as atividades do cérebro e possibilitar o diagnóstico automático de diversos distúrbios neurológicos, como epilepsia, Mal de Parkinson, Alzheimer, dentre outros, conforme mapeado em Almeida, Lima e Peres (2021). Além da aplicação na área médica, a análise dos sinais de EEG também está sendo amplamente utilizada para avanços na área das BCIs, sendo o tipo de sinal mais empregado como entrada desses sistemas.

Embora muito esforço esteja sendo aplicado em pesquisas relacionadas às BCIs, e os cientistas obtenham resultados cada vez melhores, a classificação de imagéticas motoras em sinais de EEG, e por consequência a construção de uma interface cérebro-computador eficaz, ainda é uma tarefa desafiadora. Devido à baixa razão sinal-ruído e às características não lineares do sinal, que variam no tempo, um dos principais problemas do projeto de BCIs é a identificação de características discriminantes.

Uma característica (do inglês *feature*) representa uma propriedade distinta obtida a partir de um trecho de um determinado padrão ou sinal. Também pode ser entendida como um ou mais valores derivados, não redundantes e informativos, construídos a partir

de um conjunto inicial de dados. Por meio das características, é possível minimizar a perda de informações importantes incorporadas no sinal, simplificar a quantidade de recursos necessários para descrever um grande conjunto de dados com precisão e reduzir o custo do processamento da informação (BOOSTANI; KARIMZADEH; NAMI, 2017). Com a finalidade de obter características mais relevantes do sinal de EEG, diferentes técnicas para extração de características têm sido empregadas para esse sinal nos últimos anos (AZLAN; LOW, 2015) (HUSSEIN *et al.*, 2013). As técnicas de extração de características também visam reduzir a dimensionalidade de um sinal, geralmente projetando um vetor de alta dimensão em um vetor de dimensão inferior, sem perda de informação relevante (LI *et al.*, 2018a) (DIYKH; LI, 2016). Essas técnicas são classificadas em domínio de tempo, domínio da frequência, domínio de tempo-frequência e dinâmica não-linear (BOUBCHIR; DAACHI; PANGRACIOUS, 2017).

Dentre os desafios que devem ser enfrentados estão a escolha de características e classificadores adequados, bem como o uso de técnicas de processamento de sinal apropriadas (HA; JEONG, 2019). Embora trabalhos anteriores tenham alcançado patamares que possam classificá-los como bons resultados, ainda existem possibilidades para melhorias no desempenho desses sistemas. Inclusive, novas abordagens no campo do aprendizado profundo têm sido apresentadas como soluções promissoras para decodificar sinais de EEG sem a necessidade de gerar características de modo manual (ROY *et al.*, 2019).

Com base nos desafios mencionados acima, esta Dissertação de Mestrado tem como objetivo principal investigar, dentre um conjunto de técnicas de extração de características e classificação, quais possuem maior potencialidade para serem aplicadas em sistema de BCI de mundo real. Além disso, pretende-se analisar a influência do intervalo de tempo utilizado para extrair as informações relevantes para classificação.

A presente proposta apresenta um grau significativo de contribuição em termos gerais, abrangendo o estado da arte das técnicas extração de características e classificação e uma análise envolvendo o intervalo de tempo do sinal a ser adotado para extração de características. Os resultados obtidos com esta pesquisa podem ser de grande valia para pesquisadores que estão trabalhando na área, como iniciantes que almejam um conhecimento holístico do estado da arte para desenvolvimento de futuras pesquisas, de modo a produzir conhecimento e enriquecimento para a área de BCI.

As técnicas de extração e classificação utilizadas nesta dissertação de mestrado apresentam outras possibilidades de utilização para métodos até então utilizados apenas

em outras aplicações, como por exemplo aplicações envolvendo sinais de eletrocardiograma (ECG). Apesar de algumas destas novas técnicas de extração e classificação não apresentarem uma performance relevante nos experimentos realizados, elas visam avançar no desenvolvimento de sistemas de BCI baseados em EEG que possam ser aplicados a diferentes situações e usuários.

1.1 Definição do problema

Embora existam pesquisas com resultados cada vez mais promissores, a aplicação prática das BCIs de modo eficaz ainda é um desafio com oportunidades de estudo, principalmente relacionados à etapa de pré-processamento e reconhecimento das intenções de movimento a partir da atividade cerebral. Diferentes combinações de características e técnicas de aprendizado de máquina ainda podem ser exploradas, a fim de identificar outros resultados promissores ou destacar técnicas que não proporcionam desempenho apropriado para aplicação prática.

Desse modo, podemos delimitar o principal problema abordado neste trabalho em como diferentes técnicas de extração de características e de aprendizado de máquina e suas combinações impactam o desempenho da tarefa de classificação de imagéticas motoras para sistemas de BCI baseados em sinais de EEG.

1.2 Hipóteses

A realização de um estudo abrangente envolvendo técnicas de extração de características e classificação visando o desenvolvimento de um sistema de BCI servirá como um objeto de consulta para pesquisadores da área, possibilitando uma visão holística de diferentes técnicas de extração e classificação existentes na literatura como também seus eventuais cenários de vantagens e desvantagens.

1.3 Objetivos

O objetivo geral deste trabalho é avaliar diferentes algoritmos de aprendizado de máquina para a classificação dos sinais de EEG aplicados a quatro diferentes tarefas

de imagéticas motoras. Os experimentos foram conduzidos utilizando um conjunto de dados de uma competição de BCI, disponível publicamente. Nesta condução, o protocolo estabelecido de segmentação para dados de treinamento e teste foi seguido.

Diante do objetivo geral descrito acima, e motivados pelos desafios apresentados anteriormente, podemos definir ainda os seguintes objetivos específicos:

- Comparar o desempenho de um conjunto de algoritmos tradicionais de aprendizado de máquina, utilizando características obtidas de variadas técnicas de processamento do sinal de EEG.
- Quantificar, em termos de métricas de performance, o potencial de métodos de aprendizado profundo para classificação de imagéticas motoras em sinais de EEG, por meio da implementação de algumas arquiteturas de redes neurais convolucionais.

1.4 Método de pesquisa

Para condução desta pesquisa, foi adotado como referência o método experimental, em relação ao seu gênero. Seguindo os procedimentos tradicionais da literatura, foi utilizada uma abordagem empírica na condução de um conjunto de experimentos, de modo a proporcionar uma análise comparativa entre diferentes técnicas e algoritmos de aprendizado de máquina sob diferentes configurações, e seus impactos nos resultados. A descrição dessas configurações, a fim de permitir a reprodutibilidade dos resultados, definem a abordagem metodológica quantitativa, em um procedimento descritivo.

Considerando o processo de desenvolvimento da pesquisa em sua totalidade, foram executadas atividades relacionadas à revisão exploratória e um mapeamento sistemático da literatura. O mapeamento foi utilizado nas primeiras etapas da pesquisa para identificar o atual estado da arte e oferecer pontos de partida em diversos tópicos. Os critérios e o protocolo adotados para a condução desse mapeamento estão fornecidos no apêndice [A](#).

Com relação aos experimentos, os resultados obtidos foram comparados em termos da acurácia alcançada pelas diferentes técnicas aplicadas sobre o conjunto de dados selecionado, seguindo o protocolo pré-estabelecido para as etapas de treinamento e teste. Os detalhes estão descritos no capítulo [5](#).

1.5 Estrutura do documento

Incluindo a Introdução, apresentada no capítulo 1, o estudo realizado está distribuído em um total de 6 capítulos:

- O capítulo 2 apresenta os conceitos estudados e o referencial teórico;
- o capítulo 3 detalha conceitos de técnicas de extração de características, suas categorizações nos diferentes tipos de domínios e as técnicas tradicionais de aprendizado de máquina (classificadores) implementados neste estudo;
- o capítulo 4 descreve os conceitos específicos de aprendizado profundo e das arquiteturas de redes neurais convolucionais;
- o capítulo 5 descreve o conjunto de dados utilizado e os resultados deste trabalho;
- o capítulo 6 apresenta conclusões e algumas possibilidades a serem exploradas em trabalhos futuros.

2 Fundamentos e referencial teórico

2.1 Eletroencefalograma (EEG)

Em termos gerais, o cérebro humano é composto por cerca de 100 bilhões de neurônios que se comunicam por meio de potenciais de ação pós-sinápticos (PARVEZ; PAUL, 2015). Com o auxílio dessa rede de neurônios, o cérebro controla as ações mentais e físicas de um indivíduo, transmitindo os sinais de mensagem por todo o corpo. Existem diversas técnicas, dos tipos invasivas e não-invasivas, para mapeamento de sinais cerebrais tais como a imagem por ressonância magnética funcional (do inglês *Functional Magnetic Resonance Imaging* - fMRI), a espectroscopia no infravermelho (do inglês *Near-infrared Spectroscopy* - NIRS) e a tomografia por emissão de pósitrons (do inglês *Positron Emission Tomography* - PET) (VIDYARATNE; IFTEKHARUDDIN, 2017). Dentre elas também está o eletroencefalograma (EEG). Observando apenas os métodos não-invasivos, o EEG proporciona uma análise direcionada à atividade cerebral com uma excelente resolução temporal, inferior a um milissegundo, oferecendo vantagens com relação às outras abordagens. (VAID; SINGH; KAUR, 2015)

No ano de 1929, o médico Hans Berger registrou os primeiros sinais elétricos do cérebro humano, os primeiros registros de um eletroencefalograma (BERGER, 1929). O EEG é uma ferramenta capaz de registrar sinais da atividade elétrica cerebral gerada em decorrência dos potenciais de ação pós-sinápticos de atividades corticais e subcorticais por meio da diferença de potencial entre os eletrodos utilizados na coleta, que são colocados sobre o couro cabeludo. A figura 1 ilustra um registro de sinal de EEG.

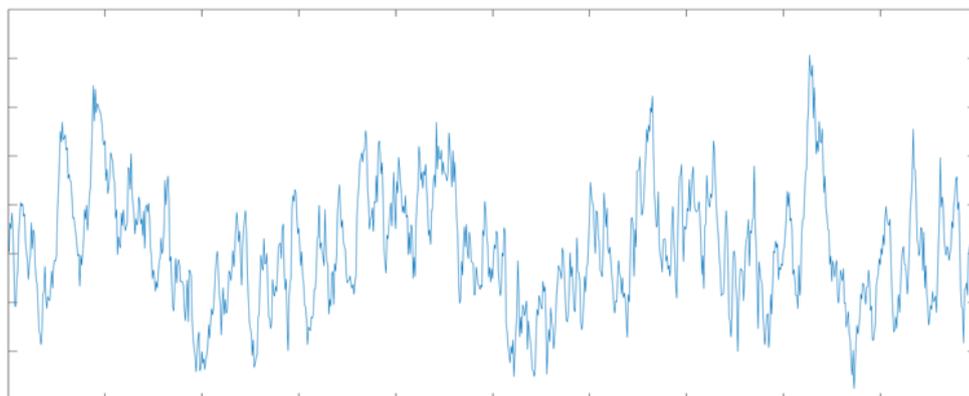


Figura 1 – Representação de um segmento de sinal de EEG

O EEG pode ser descrito como uma série temporal, de natureza não-linear, não gaussiana e não estacionária. O intervalo de frequência normal para um sinal de EEG está contido entre 0,1 e 100Hz, com amplitudes entre 1 μV e 200 μV . Em geral, os sinais de EEG têm um amplo conteúdo espectral, mas também expõem a atividade oscilatória em faixas de frequência específicas, apresentando queda em sua amplitude espectral conforme a frequência aumenta (BLINOWSKA; DURKA, 2006).

2.1.1 Tipos de oscilações neurais

Embora os dados brutos obtidos do EEG sejam descritos em função do tempo, as oscilações neurais são geralmente visualizadas em termos de frequência usando um estimador de densidade espectral ou transformada de Fourier. Os diferentes ritmos, como também são conhecidas essas faixas de frequência, são denominados delta, teta, alfa, beta, gama e mu (BLINOWSKA; DURKA, 2006) (BASTOS-FILHO, 2020). A faixa delta é observada de modo mais comum em diferentes estágios do sono ou coma. Observa-se a faixa teta associada a emoções de frustração e também estágios de meditação. A faixa alfa está associada a funções cognitivas. Já a faixa beta representa atividades de concentração e atenção. A faixa gama está associada a um exercício extremo de concentração e aprendizado (BLINOWSKA; DURKA, 2006). E a faixa mu está associada especificamente a movimentos musculares ou intenção de movimento. A faixa mu coincide com a faixa de frequências do ritmo alfa, porém é coletada na região central do escalpo, e apresenta diferenças topográficas e fisiológicas do ritmo alfa (BASTOS-FILHO, 2020).

Além de frequências bem-definidas, os ritmos também apresentam intervalos de amplitude específicos. A tabela 1 mostra em resumo esses intervalos (VAID; SINGH; KAUR, 2015).

Tabela 1 – Diferentes faixas de frequência dos sinais de EEG

Ritmo	Faixa de Frequência (Hz)	Amplitude (μV)
Delta	0,1 - 4	20 - 200 (alta)
Teta	4 - 7	Mais de 20
Alfa	7 - 13	30 - 50
Mu	8 - 13	Menor que 50
Beta	13 - 31	5 - 30
Gama	Acima de 31	menos de 5

Fonte – Wallace Almeida, 2021

2.1.2 Disposição dos eletrodos e o sistema internacional 10-20

Para a medir a amplitude dos sinais elétricos desses impulsos, os eletrodos são distribuídos ao longo do couro cabeludo. O sistema internacional 10-20, conforme descrito em [Klem *et al.* \(1958\)](#) utiliza uma disposição de 21 eletrodos a saber: Fp1, F3, F7, C3, T3, P3, T5, O1, Fp2, F4, F8, C4, T4, P4, T6, O2, Fz, Cz, Pz, A1 e A2. As posições dos eletrodos são determinadas em relação a pontos de referência anatômicos específicos na cabeça, e são separados por distâncias de 10% ou 20%, sendo que a distância entre o ponto pré-auricular esquerdo e direito é considerada como referência de 100%.

Nesse sistema, a letra (ou duas letras) no nome dos eletrodos indica a região geral do cérebro onde o eletrodo é colocado. Desta forma temos Fp para fronto-polar, F para frontal, C para central, P para parietal, T para temporal, O para occipital e A para pré-auricular. Cada nome de eletrodo termina com um número, ou letra, indicando a distância até a linha média. Números maiores indicam distâncias maiores da linha média, enquanto os eletrodos colocados na linha média são marcados com um "z". Os eletrodos localizados no hemisfério esquerdo apresentam numeração ímpar, e os representantes do hemisfério direito apresentam numeração par. A figura 2 ilustra a distribuição do padrão internacional.

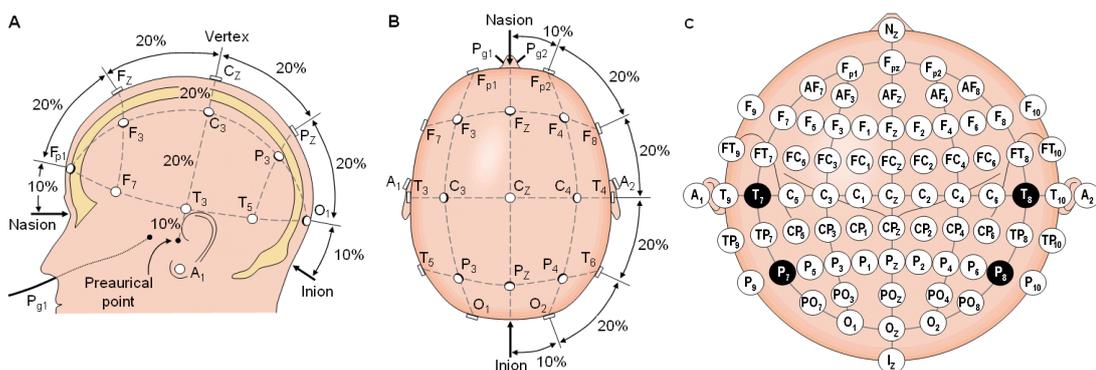


Figura 2 – Distribuição dos eletrodos no couro cabeludo pelo sistema internacional 10-20 (A,B) e 10-20 estendido (C)

Fonte – [Fu, Daly e Cavusoglu \(2006\)](#)

2.1.3 Aplicabilidade dos sinais de EEG

O EEG apresenta alguns benefícios quando comparado às outras técnicas para medir atividade do cérebro. Conforme descrito anteriormente, o principal deles é a alta resolução temporal do sinal, ou seja, é possível realizar milhares de leituras a partir de múltiplos eletrodos, em um único segundo. Esse fato torna o EEG uma tecnologia ideal para estudar atividades cognitivas e emocionais, a maioria das quais ocorre na escala dos milissegundos. Outra vantagem está relacionada ao fato de ser possível medir a atividade neural diretamente, diferente do que ocorre com o fMRI, que não mede diretamente essa atividade, mas infere a atividade neural real (LOTZE *et al.*, 1999). Por fim, o EEG é um método não invasivo, e o equipamento necessário para captura é relativamente barato, portátil e de fácil operação (LI *et al.*, 2018b).

No entanto, o EEG também apresenta alguns aspectos menos vantajosos. O principal deles é a baixa resolução espacial, em contraste com a resolução temporal. A atividade neural é transmitida do cérebro para o couro cabeludo e eletrodos, com as correntes fluindo a partir da parte interna do cérebro até a superfície do crânio, por onde se espalha. Por essa razão, as correntes não estão restritas à vizinhança imediata da origem do sinal. Como o crânio é um mau condutor, a corrente é distribuída e cada eletrodo acaba recebendo sinais de múltiplos neurônios, reduzindo as possibilidades de uma localização espacial com alta precisão (LANFER *et al.*, 2012). Além disso, a condutividades dos tecidos da cabeça varia entre os indivíduos, e também para um mesmo indivíduo em função da idade, comorbidades ou fatores ambientais (HOSSEINI; HAJISAMI; POMPILI, 2016).

O EEG também é muito sensível ao movimento do indivíduo e a ruídos e interferências externas. Os eletrodos usados na gravação de EEG não distinguem os geradores dos sinais elétricos que recebem, e portanto captam também outras fontes que não seja especificamente dos neurônios. A atividade registrada que não é de origem cerebral é denominada artefato. Artefatos são sinais não cerebrais que muitas vezes causam variações nas gravações nos domínios temporal e espectral dentro de uma ampla faixa de frequência (NUNEZ *et al.*, 1997). A fonte interna de artefatos está relacionada às atividades fisiológicas do indivíduo como, movimento dos olhos, batimento cardíaco, transpiração ou movimentos voluntários ou involuntários. Fontes externas de artefatos são interferências ambientais, como ruído da rede elétrica, contatos ruins entre o eletrodo e a pele ou interferências

do equipamento de gravação, cabos e etc (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017).

O EEG é um exame amplamente utilizado e com diversas aplicações. Na área clínica, ele é utilizado no apoio ao diagnóstico de distúrbios neurológicos, como a epilepsia, além de contribuir com estudos sobre os estágios do sono (JAISWAL; BANKA, 2018) (JIANG *et al.*, 2019). Esse sinal também é amplamente utilizado na pesquisa em neurociência e psicologia, como ferramenta para estudo do cérebro e seu funcionamento, dos níveis de cansaço mental e das emoções (THIBODEAU; JORGENSEN; KIM, 2006) (TANDLE *et al.*, 2018). Além destas, existem diferentes abordagens para realização da tarefa de classificação de sinais de EEG com foco em sistemas de BCI aplicadas nos últimos anos, que também é o foco deste trabalho.

2.2 Interfaces cérebro-computador

Existem diversas maneiras de um indivíduo interagir e fornecer comandos a um computador. Algumas delas são populares há anos, como teclados e mouses junto às interfaces gráficas. Mais recentemente, foram desenvolvidas interfaces que podem ser controladas por toque, por gestos, ou ainda por comandos de voz. O surgimento de novas formas busca tornar a interação entre um usuário e o computador mais natural e intuitiva (WOLPAW JONATHAN R.AND WOLPAW, 2012).

Uma Interface cérebro-computador, ou BCI, é um sistema que combina *hardware* e *software* a fim de permitir a um indivíduo o envio de comandos para um dispositivo externo a partir de sinais cerebrais, atuando como um canal de comunicação entre o cérebro humano e um sistema de computador.

Os sinais de EEG são os principais sinais utilizados na entrada das BCIs. Um dos principais desafios é como extrair características de sinais EEG, variáveis no tempo e classificar os sinais com a maior precisão possível (VAID; SINGH; KAUR, 2015). Nesse cenário, o avanço nos estudos das técnicas de extração e seleção de características ganham destaque em virtude da influência sobre a eficácia dos classificadores.

A utilização de um sistema BCI geralmente necessita de duas etapas. A primeira etapa é caracterizada pelo treinamento, no qual o sistema é calibrado a fim de identificar

os padrões cerebrais de interesse. Na segunda etapa, a operacional, o sistema efetivamente reconhece os padrões da atividade cerebral e os traduz em comandos para ao computador.

As motivações iniciais para os sistemas de BCI correspondem ao auxílio a indivíduos que apresentam alguma função motora comprometida, como por exemplo paralisia por esclerose lateral amiotrófica, para controle e interação com o ambiente sem a necessidade de movimento muscular. As BCIs também podem ser amplamente utilizadas na área de medicina, auxiliando no aprimoramento da identificação biométrica (VIEIRA, 2019), além do apoio à execução de tarefas motoras (SUN; ZHOU, 2014).

Outras aplicações para as BCIs estão relacionadas ao controle de dispositivos mecânicos, como exoesqueletos, próteses, cadeira de rodas, ou comandos para dispositivos em casas inteligentes, como controle de luz ou temperatura do ambiente e interação com jogos eletrônicos.

2.2.1 Sistemas de BCI baseados em EEG e seus componentes

Para calibrar o sistema, um conjunto de dados de treinamento precisa ser coletado previamente do usuário. Os sinais de EEG são altamente específicos para o indivíduo em particular, o que implica na necessidade da maioria dos sistemas BCI atuais serem calibrados especificamente para cada usuário (HE; WU, 2019). Este conjunto de dados de treinamento contém sinais de EEG registrados enquanto o usuário executa cada tarefa mental de interesse várias vezes, de acordo com as instruções fornecidas previamente.

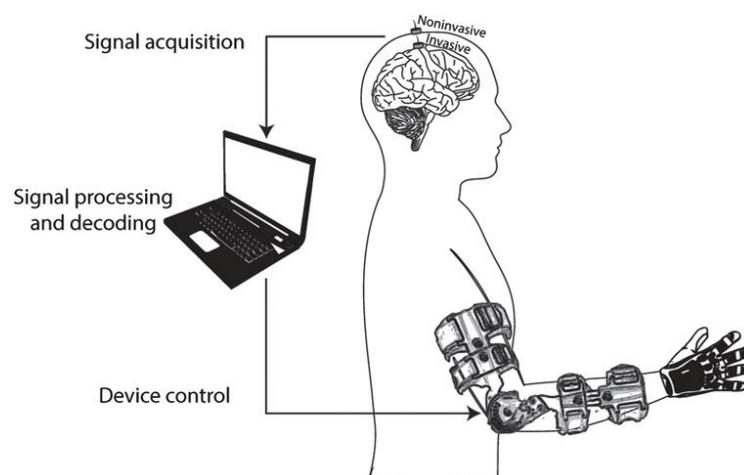


Figura 3 – Modelo de BCI baseado em sinais de EEG

Fonte – López-Larraz *et al.* (2018)

Os sinais de EEG são geralmente pré-processados utilizando diversos filtros espaciais e espectrais, e algumas características são extraídas desses sinais para representá-los de modo conciso com mínima perda de informação. Finalmente, essas características de EEG são classificadas antes de serem traduzidas em um comando para uma aplicação e antes que uma resposta seja fornecida ao usuário, indicando se um comando mental específico foi reconhecido ou não (LOTTE *et al.*, 2018).

Um modelo geral de BCI apresenta os seguintes componentes (BASHASHATI *et al.*, 2007):

- **Eletrodos e amplificador para o sinal de EEG:** tem como atribuição a captura do sinal de origem.
- **Filtro de artefatos:** responsável por remover ou reduzir os artefatos presentes originalmente no sinal.
- **Gerador de características:** esse componente transforma o sinal bruto em um conjunto de características que serão utilizadas posteriormente por um classificador. Este componente concentra as tarefas de extração e seleção de características.
- **Tradutor de características:** utilizado para traduzir as características (obtidas pelo componente anterior) em sinais a serem enviados para o dispositivo a ser controlado.
- **Dispositivo controlado:** representa o dispositivo efetivamente controlado pelo sistema de BCI, como uma cadeira de rodas por exemplo.

2.2.2 Sinais de controle

Os sinais cerebrais envolvem vários fenômenos simultâneos relacionados a tarefas cognitivas. Nesse sentido, os fenômenos fisiológicos de alguns sinais cerebrais foram decodificados de modo que as pessoas possam aprender a manifestá-los de acordo com sua vontade, e então permitir que os sistemas BCI interpretem suas intenções. Esses sinais são considerados possíveis sinais de controle em BCIs. Dentre os principais fenômenos neurológicos utilizados em BCIs, quatro deles são detalhados a seguir: potenciais evocados visualmente (do inglês *Visual Evoked Potentials* - VEP), potenciais corticais lentos (do inglês *slow cortical potentials* - SCP), potenciais evocados P300 e ritmos sensório motor (do inglês *sensorimotor rhythms* - SMR) (WOLPAW *et al.*, 2002).

- **VEP**: são modulações da atividade cerebral que ocorrem no córtex visual após um estímulo visual. Uma BCI baseada nesse paradigma exhibe vários objetos ao indivíduo, como faces de pessoas por exemplo, piscando em frequências diferentes e realiza uma análise dos picos de frequência em seu EEG, para cada objeto que o usuário está olhando. Com base nos picos de frequência, a BCI pode acionar ou não um dispositivo.
- **SCP**: potenciais corticais lentos são mudanças de tensão que ocorrem geralmente em frequências abaixo de 1Hz. As pessoas podem ser treinadas para controlar esses potenciais e produzir mudanças positivas e negativas. Uma mudança ocorre quando os valores do sinal EEG estão abaixo, ou acima, de algum nível de linha base considerada normal para o indivíduo por mais de 300ms. Em uma BCI baseada em SCP, um usuário recebe algumas informações sobre o valor da tensão atual do sinal de EEG, e então esse usuário tenta invocar uma mudança potencial positiva ou negativa.
- **P300**: o potencial P300 é um crescimento da amplitude do sinal de EEG, ou pico positivo, que ocorre aproximadamente 300ms após a apresentação de um estímulo aguardado por um indivíduo. O potencial P300 também ocorre após apresentar um estímulo alvo em uma sequência de estímulos não-alvo. Um exemplo de BCI baseado no paradigma P300 é o *P300 speller*, um aplicativo que mostra uma matriz de letras ao usuário e destaca aleatoriamente uma linha ou coluna na matriz. O objetivo do algoritmo é determinar para qual coluna e para qual linha ocorre o potencial P300, determinando para qual letra o usuário está olhando no momento.
- **SMR**: os ritmos sensório motor representam mudanças na potência das faixas mu/alfa e beta durante a execução ou imaginação do movimento. Esse sinal de controle será detalhado na seção 2.2.4.

2.2.3 Tipos de sistema

De acordo com as definições apresentadas em [Nicolas-Alonso e Gomez-Gil \(2012\)](#), os sistemas de BCI para EEG podem ser classificados em dois tipos, com relação à natureza do sinal de entrada: exógenos e endógenos. Essa classificação também aparece na literatura como referência a potenciais evocados e potenciais espontâneos, respectivamente. O primeiro

tipo considera a presença de um estímulo externo para gerar um efeito identificável no sinal, podendo estar relacionados a um estímulo visual ou um evento, como um contato. Já o segundo tipo corresponde aos componentes observados no sinal sem a aplicação de um estímulo externo.

Em geral, os sistemas baseados em EEG que trabalham com potenciais evocados podem ainda ser separados em mais duas categorias: aqueles dependentes de potenciais evocados visualmente (VEPs), que consiste de sinais cerebrais gerados em resposta a um estímulo visual, e potenciais relacionados a eventos (ERPs), que consiste de sinais cerebrais gerados em resposta a sinais sensoriais ou eventos cognitivos. Os potenciais visualmente evocados em estado estacionário (SSVEPs) são um dos mais amplamente pesquisados na área de BCIs baseadas em VEP, pois são capazes de captar a entrada de comandos de maneira relativamente rápida e com precisão, ao mesmo tempo que exigem pouco treinamento do usuário (PADFIELD *et al.*, 2019).

A respeito da modalidade de processamento dos dados de entrada, os sistemas BCI podem ser classificados como síncronos ou assíncronos. Os sistemas de BCIs síncronos analisam os sinais do cérebro durante janelas de tempo predefinidas. Todo sinal fora dessa janela é desconsiderado. A vantagem de um sistema BCI síncrono é que o início da atividade mental é conhecido com antecedência e associado a uma tarefa específica. Isso simplifica o projeto e a avaliação dos sistemas de BCI síncronos. Por outro lado, os sistemas de BCIs assíncronos analisam continuamente os sinais do cérebro, independentemente de quando o usuário age. Desse modo, oferecem um modo mais natural de interação quando comparado ao sistema síncrono. No entanto, os modelos assíncronos são mais complexos e computacionalmente custosos (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Os sistemas de BCIs endógenos, também conhecidos como ativos, são, em geral, mais desafiadores de projetar devido à relação sinal-ruído, do inglês *Signal-to-Noise Ratio* (SNR), ser mais baixa e à forte variabilidade entre indivíduos distintos (PFURTSCHELLER; NEUPER, 2001).

2.2.4 Ritmos sensório motor e imagéticas motoras

Os ritmos sensório motor são um sinal de controle para BCIs ativas que se baseiam nas oscilações neurais, localizadas nas faixas mu/alfa e beta. Os SMR podem suportar dois

tipos de modulações de amplitude conhecidas como dessincronização relacionada a eventos (*Event-Related Desynchronization* - ERD) e sincronização relacionada a eventos (*Event-Related Synchronization* - ERS) que são geradas por estimulação sensorial, comportamento motor e imagens mentais. A ERD representa uma redução de amplitude do ritmo, enquanto a ERS implica em aumento de amplitude. Ao contrário dos ERPs, ERD e ERS não estão restritos a uma única faixa para uma apresentação de estímulo e, portanto, não podem ser identificados pela média das amplitudes do sinal de EEG (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

O SMR pode ser induzido pelo ensaio mental de uma tarefa física. Um exemplo comum de BCI espontâneo são as imagéticas motoras, do inglês *Motor Imagery* (MI), que exige que o usuário imagine o movimento de um membro. Mudanças na atividade mu e beta nos sinais de EEG são usadas para identificar o tipo de tarefa de MI que está sendo realizada (PADFIELD *et al.*, 2019). Em um nível neurofisiológico, regiões cerebrais semelhantes são ativadas tanto durante a execução motora quanto na imagética motora. Conforme descrito em Hanakawa, Dimyan e Hallett (2008), estudos baseados em fMRI mostraram padrões de ativação semelhantes durante a imaginação motora e a execução real do movimento. A figura 4 representa esses padrões similares de ativação cerebral.

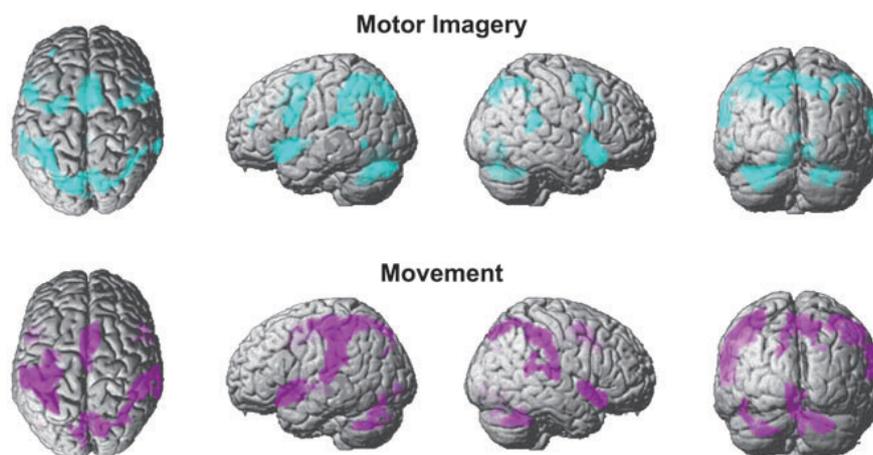


Figura 4 – Comparativo entre registros de fMRI de imagéticas motoras (azul) e movimento real (roxo) para a tarefa relacionada aos membros superiores

Fonte – Adaptado de Hanakawa, Dimyan e Hallett (2008)

Além disso, o fenômeno de ERD ou ERS relacionado às ações de MI tem diferentes aspectos espaciais e intensidade para membros diferentes do corpo, ocorrendo de modo muito mais intenso no hemisfério do lado do corpo oposto ao membro (hemisfério cruzado), assim como o ERP. Ou seja, se o indivíduo imagina um movimento com a mão direita, o

ERD ou ERS ocorre principalmente no hemisfério esquerdo. Da mesma forma, se o indivíduo imagina um movimento com a mão esquerda, a manifestação ocorre principalmente no hemisfério direito. Esse padrão é ilustrado na figura 5. A separação dos movimentos dos pés e braços são mais difíceis de separar um do outro, porque nesse caso áreas maiores do córtex motor são afetadas.

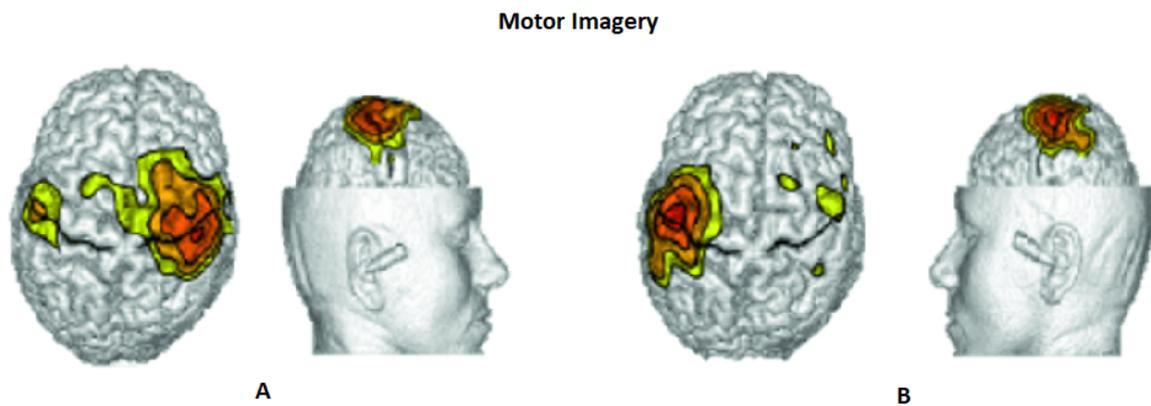


Figura 5 – Manifestação dos ativação em cada hemisfério para MI das mãos esquerda (A) e direita (B)

Fonte – Adaptado de [Andrade et al. \(2020\)](#)

As imagéticas motoras são muito comumente usadas em sistemas BCI porque permitem o desenvolvimento de BCIs ativas assíncronas. A principal vantagem das BCIs baseadas em MI é que permitem ao usuário controlar o sistema espontaneamente, por meio da imaginação da execução de um movimento. Por outro lado, elas sofrem de alta variabilidade entre um mesmo indivíduo e também entre indivíduos e, portanto, requerem treinamento intenso do usuário e longos intervalos de tempo de calibragem para atingir um desempenho que torne sua utilização viável.

3 Processamento do sinal de EEG

3.1 Técnicas de extração de características

Conforme destacado anteriormente, as técnicas de extração de características (*feature extraction*) são classificadas em domínio do tempo, domínio da frequência, domínio de tempo-frequência e dinâmica não-linear. No mapeamento Almeida, Lima e Peres (2021), cujo protocolo é apresentado no apêndice A, estão identificadas as principais técnicas empregadas, e seus respectivos domínios, para processamento de sinais de EEG no contexto das interfaces cérebro-computador e também de diagnósticos de distúrbios neurológicos.

O domínio do tempo é o domínio original do sinais de EEG e, nesse contexto, as características no domínio do tempo podem representar as particularidades morfológicas do sinal. Essas características podem ser baseadas no comportamento da amplitude, (mediana, intervalo inter-quartil), na entropia (entropia aproximada, entropia de Shannon), e também em métricas estatísticas (média, variância, etc.) (BOUBCHIR; DAACHI; PANGRACIOUS, 2017). Dentre as diferentes categorizações de características estudadas, as de domínio do tempo são aquelas que apresentam maior facilidade de interpretação e são mais adequadas para aplicações em tempo real, devido ao custo computacional para processamento ser menor em comparação com outras técnicas. (BOOSTANI; KARIMZADEH; NAMI, 2017).

Frequência pode ser definida como uma medida de ocorrência de algum evento de interesse em um intervalo de tempo especificado (HARPALE; BAIRAGI, 2016). Assim, a análise do sinal no domínio da frequência permite visualizar os diferentes componentes de frequência presentes no sinal e estudar suas mudanças e comportamento. Para que essa análise das características seja possível, é necessário obter uma representação em termos das frequências por meio das Transformadas de Fourier (BOUBCHIR; DAACHI; PANGRACIOUS, 2017) (JENKE; PEER; BUSS, 2014). Uma limitação apresentada por estudos de sinais realizados exclusivamente no domínio da frequência é o fato de não ser possível identificar os instantes de tempo no intervalo analisado que as frequências de interesse ocorrem (HARPALE; BAIRAGI, 2016).

Embora as análises em domínio do tempo possam fornecer informações temporais, não é possível obter diretamente informações referentes às frequências na mesma análise. Nesse contexto as análises no domínio de tempo-frequência apresentam a vantagem de extraírem informação desses dois domínios simultaneamente. Ao se trabalhar com sinais

não estacionários, como no caso dos sinais de EEG, os métodos que atuam no domínio de tempo-frequência tendem a perder menos informação relevante, estando mais aptos a lidar com esse tipo de comportamento variável ao longo do tempo (JENKE; PEER; BUSS, 2014) (BOOSTANI; KARIMZADEH; NAMI, 2017).

Sendo conhecidos os aspectos complexos e não-lineares apresentados pelo sinal de EEG, diferentes técnicas de dinâmica não-linear são frequentemente empregadas para o processamento desse sinal (BOOSTANI; KARIMZADEH; NAMI, 2017). Também conhecida como medidas de complexidade, as técnicas dessa categoria auxiliam na compreensão de fenômenos fisiológicos complexos, como mutações e comportamentos caóticos. Juntamente com a pressão sanguínea, os sinais de EEG são representantes dos processos definidos como caóticos (ZHAO *et al.*, 2019).

3.1.1 Padrões Espaciais Comuns

A técnica de padrões espaciais comuns (do inglês *Common Spatial Patterns* - CSP) é uma abordagem eficaz para extrair características relevantes para classificação de sinais de EEG. Os CSP discriminam os sinais de EEG decompondo-os em padrões espaciais que aumentam a diferença entre duas classes distintas. O principal objetivo da aplicação dos CSP é maximizar a variância de uma classe do sinal de EEG e minimizar a variância da outra. Originalmente proposto para aplicação em um problema binário, adotamos neste trabalho a utilização da estratégia de banco de filtros para os CSP, segmentando um problema com múltiplas classes em k classes binárias (KHAN *et al.*, 2020).

Sejam X_1, X_2, X_3 , e X_4 matrizes $N \times G$ representando as quatro classes do sinal EEG pré-processado, onde N indica o número de canais de EEG e G corresponde ao número de amostras de dados. Os passos realizados pelo CSP para múltiplas classes, seguindo a abordagem utilizada em Khan *et al.* (2020), é detalhado a seguir.

A covariância espacial normalizada C é calculada como:

$$C_k = \frac{X_k^i X_k^{iT}}{tr(X_k^i X_k^{iT})} \quad (1)$$

onde X_k^{iT} é a transposta da matriz de X_k^i para $k = 1, 2, 3, 4$ e $tr(X)$ é o traço de uma matriz X , que é a soma dos elementos diagonais dessa matriz. As quatro matrizes de covariância espacial são somadas do seguinte modo:

$$C = \sum_{k=1}^4 C_k \quad (2)$$

e matrizes de covariância para dados de outras classes C' são dadas como:

$$C'_k = \sum_{j \neq k} C_j \quad (3)$$

onde $j = 1,2,3,4$. A fatoração da matriz C é feita pela decomposição em autovalores

$$C = U_0 \Lambda U_0^T \quad (4)$$

Aqui, Λ é a matriz quadrada de ordem N contendo os elementos diagonais como autovalores e U_0 corresponde à matriz de autovetores. O processo de clareamento de dados é realizado como:

$$P = \Lambda^{-\frac{1}{2}} U_0^T \quad (5)$$

onde P é a matriz de clareamento. As matrizes de covariância C_k e C'_k são transformadas para calcular as matrizes intermediárias S_k e S'_k .

$$S_k = P C_k P^T \quad (6)$$

$$S'_k = P C'_k P^T \quad (7)$$

Ambas as matrizes compartilham autovetores comuns, e a soma das matrizes de autovalores de ambos resultam na matriz Identidade. Conseqüentemente, o autovalor máximo para S_k irá adquirir o autovalor mínimo para S'_k e vice-versa, portanto, maximizando a variância entre S_k e S'_k pela transformação da matriz X_k no espaço dos autovetores. A projeção da matriz para cada uma das classes é calculada como:

$$W_k = U_k^T P \quad (8)$$

onde U_k^T é a matriz de autovetores. As primeiras e as últimas m linhas de W_k são obtidas para criar um filtro espacial $2m \times N$. W_{kS} que é utilizado para filtrar espacialmente X_k^i , ou seja,

$$Z_k = W_{kS} X_k^i \quad (9)$$

As matrizes W_{kS} para as quatro classes ($k = 1,2,3,4$) são concatenadas resultando em um filtro espacial W_S de ordem $N \times 8m$. Para uma implementação que utiliza uma separação do sinal em quatro faixas de frequências, os sinais obtidos pelo filtro passa-faixa $x_{band}(x1; x2; x3; x4)$ de ordem $N \times T$ para cada ensaio são filtrados espacialmente e o log da variância desses sinais é calculado como vetores de características de dimensões $1 \times 8m$:

$$F_{band} = \frac{\log([\text{diag}(W_S^T x_{band} x_{band}^T W_S)])}{\text{tr}(\text{diag}(W_S^T x_{band} x_{band}^T W_S))} \quad (10)$$

3.1.2 Dimensão Fractal - Katz e Higuchi

Dimensão fractal consiste de um índice estatístico de complexidade, indicando como os detalhes em um determinado padrão físico (ou objeto) mudam com a escala em que são medidos. O valor desse índice é geralmente uma fração, dando origem ao nome dimensão fractal (RAGHAVENDRA; Narayana Dutt, 2009). Nesse estudo, optamos por analisar o desempenho dos métodos de Katz e Higuchi. Para descrever o método de Katz, proposto em Katz (1988), considere a formulação $s(i) = (x_i, y_i)$, $i = 1, 2, \dots, N$, onde x_i são os valores da abcissa e y_i são os valores da ordenada. Se os pontos $s(i)$ e $s(j)$ são representados como (x_i, y_i) e (x_j, y_j) , respectivamente, a dimensão fractal da curva que representa uma série temporal pode ser definida como:

$$D = \frac{\log(L)}{\log(d)} \quad (11)$$

onde L é o comprimento total da curva ou a soma das distâncias euclidianas entre pontos sucessivos na mesma curva, e d é o diâmetro estimado como $d = \max(\text{dist}(s(i), s(j)))$, $i, j = 1, \dots, N$. Se não houver interseções na curva, i pode ser definido igual a 1 e d pode ser estimado como a distância máxima entre a primeira amostra e a mais distante de todas as amostras subsequentes em $s(i), i = 2, \dots, N$.

Em Katz (1988) foi proposto normalizar d e L pelo comprimento do passo médio, definido como L/Nl , quando os números não são adimensionais. Dessa forma, a equação 11 torna-se

$$D = \frac{\log(Nl)}{\log(Nl) + \log(\frac{d}{L})} \quad (12)$$

onde $Nl = N - 1$.

O método de Higuchi (HIGUCHI, 1988), é especialmente indicado para tratar formas de onda como objetos. Considere $s = s(1), s(2), \dots, s(N)$ como uma realização da série temporal a ser analisada. A partir desta realização, novas realizações são construídas e representadas por s_m^k , sendo cada uma delas definida como:

$$s_m^k = s(m), s(m+k), \dots, s(m+Mk), m = 1, 2, \dots, k \quad (13)$$

onde m e k são inteiros, indicando o tempo inicial e o tempo de intervalo respectivamente, $M = \lfloor \frac{(N-m)}{k} \rfloor$. Para cada uma das realizações s_m^k construídas, o comprimento médio $L_m(k)$ é calculado como:

$$L_m(k) = \frac{1}{k} \left\{ \frac{N-1}{Mk} \sum_{i=1}^M (|s(m+ik) - s(m+(i-1)k)|) \right\} \quad (14)$$

onde $\frac{(N-1)}{Mk}$ é um fator de normalização. A duração da realização $L(k)$ para o instante de tempo k é calculada como a média dos valores para $m = 1, 2, \dots, k$. Isso é $L(k) = \sum_{m=1}^k L_m(k)$.

Ao final, a dimensão fractal de Higuchi é estimada como o coeficiente de inclinação pelo método dos mínimos quadrados a partir da relação entre $\log(L(k))$ e $\log(\frac{1}{k})$:

$$HFD = \alpha(\{\log(\frac{1}{k}), \log(L(k))\}) \quad (15)$$

onde L é o comprimento médio de cada intervalo selecionado e $\alpha(\cdot)$ é o coeficiente angular.

3.1.3 Transformada Discreta de Wavelet

Transformadas Wavelet (do inglês *Wavelet transforms* - WT) proporcionam um meio mais flexível para representar um sinal no domínio de tempo-frequência ao permitir a utilização de janelas de tamanho variável, sendo amplamente aplicadas nas áreas de Engenharia Biomédica para solucionar uma variedade de problemas. Ao analisar sinais biológicos, como o EEG, em diferentes resoluções de tempo-frequência, WT é capaz de processá-los de modo eficiente durante a etapa de extração de características (SHARMILA; MAHALAKSHMI, 2017).

De modo geral, a transformada wavelet de um sinal $x(n)$ pode ser definida no domínio contínuo como:

$$wt(s, \tau) = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} x(t) \Psi^*\left(\frac{t - \tau}{s}\right) dt \quad (16)$$

onde $\Psi^*(.)$ é o conjugado complexo da função $\Psi(.)$ escalonada e deslocada. Enquanto o parâmetro s é responsável por esticar a função wavelet (o processo de dilatação), o parâmetro τ a desloca ao longo do eixo do tempo (o processo de translação). De maneira específica, a família de wavelets escalonadas e deslocadas pode ser definida como:

$$m = \frac{1}{\sqrt{s}} \Psi\left(\frac{t - \tau}{s}\right), s > 0, \tau \in R \quad (17)$$

De acordo com o *framework* geral de Transformada Contínua de Wavelet (*Continuous Wavelet Transform* - CWT), ambos s e τ podem ser variados de maneira contínua, no entanto, essa abordagem resulta em informação redundante além do grande custo computacional de tempo e alocação de memória. Nesse caso, tornar discretos os parâmetros de escala e translação permite reduzir a redundância (KOCADAGLI; LANGARI, 2017).

Para fazer análise no domínio de tempo-frequência de um sinal EEG $x(n)$, utilizamos a Transformada Discreta de Wavelet (do inglês *Discrete Wavelet Transform* - DWT). O objetivo principal dessa análise é evidenciar os detalhes do sinal por meio de um processo de decomposição. Nesse processo são produzidos sub-bandas compostas pelos coeficientes wavelets utilizando filtros complementares, filtro passa-baixa $g[n]$ e filtro passa-alta $h[n]$. Fundamentalmente, a DWT produz duas faixas de frequências com diferentes resoluções e escalas em cada nível da decomposição (KOCADAGLI; LANGARI, 2017). Obtemos a DWT a partir da discretização dos parâmetros apresentados na equação 16:

$$DWT(j, k) = \frac{1}{\sqrt{2^j}} \int_{-\infty}^{+\infty} x(t) \Psi\left(\frac{t - 2^j k}{2^j}\right) dt \quad (18)$$

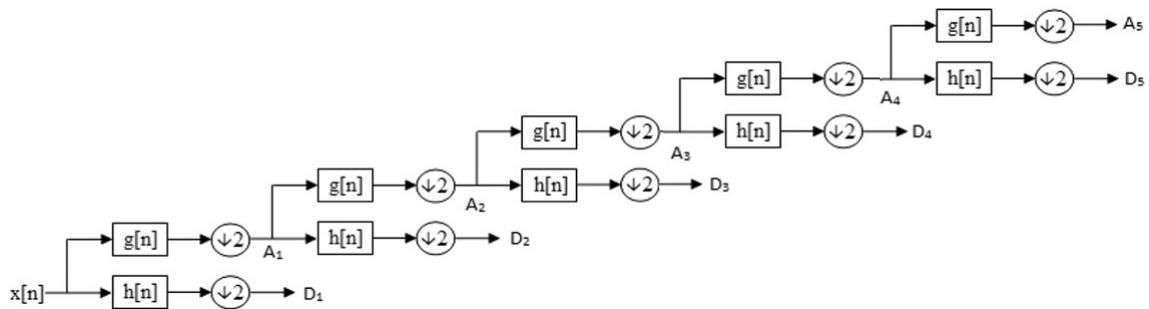
Cada nível consiste de dois filtros digitais e dois redutores de qualidade (*downsamplers*) numa escala de 2. As saídas dos redutores do primeiro filtro passa-alta e do primeiro filtro passa-baixa produzem os coeficientes detalhados D1 e os coeficientes de aproximação A1, respectivamente. A cada nível do processo de decomposição, a resolução da frequência é dobrada através da filtragem, e a resolução do tempo é reduzida pela metade através da redução de qualidade. A figura 6 representa a decomposição wavelet em 5 níveis de um sinal. Os coeficientes A1, D1, A2, D2, A3, D3, A4, D4, A5 e D5 e suas respectivas faixas de frequência estão listados na tabela 2, onde fs é a frequência de amostragem original do sinal de entrada $x(t)$ (SHARMILA; MAHALAKSHMI, 2017).

Tabela 2 – Sub-bandas de frequência para decomposição wavelet em 5 níveis

Coefficientes	Faixas de frequência
A1	0 - $f_s/4$
D1	$f_s/4$ - $f_s/2$
A2	0 - $f_s/8$
D2	$f_s/8$ - $f_s/4$
A3	0 - $f_s/16$
D3	$f_s/16$ - $f_s/8$
A4	0 - $f_s/32$
D4	$f_s/32$ - $f_s/16$
A5	0 - $f_s/64$
D5	$f_s/2$ - $f_s/4$

Fonte – Wallace Almeida, 2021

Figura 6 – Decomposição wavelet em 5 níveis para um sinal de EEG



Fonte – Sharmila e Mahalakshmi (2017)

A escolha da wavelet apropriada e o número de níveis de decomposição é muito importante na análise de sinais usando a DWT. O número de níveis de decomposição é definido com base nos componentes da frequência dominante do sinal. Os níveis são escolhidos de modo que as partes do sinal que se correlacionam bem com as frequências necessárias para a classificação do sinal sejam retidas nos coeficientes wavelet (SHARMILA; MAHALAKSHMI, 2017).

3.1.4 Decomposição de Modo Empírico

A Decomposição de Modo Empírico (do inglês *Empirical Mode Decomposition* - EMD) é um método para análise de sinais proposto originalmente em Huang *et al.* (1998). Esse método utiliza uma abordagem direcionada pelos dados, não sendo necessário assumir uma definição prévia como uma função-mãe *wavelet*, decompondo o sinal de entrada de maneira adaptativa em um número finito de funções, limitadas por frequência, denominadas

funções de modo intrínseco (do inglês *Intrinsic Mode Functions* - IMF) (LI *et al.*, 2013) (TRAD; AL-ANI; JEMNI, 2016).

As *IMFs* podem ser aplicadas na análise de sinais não-lineares e não-estacionários. Cada *IMF* deve satisfazer duas condições básicas (LI *et al.*, 2013):

- (1) Em todo o conjunto de dados, o número de pontos extremos e o número de cruzamento zero devem ser iguais ou diferir em no máximo um;
- (2) Em cada ponto, o valor médio dos envoltórios definidos pelo máximo local e o mínimo local deve ser zero.

O princípio da *EMD* é fundamentado na decomposição do sinal original $x(t)$, possivelmente composto por diversas frequências, em n *IMFs* com frequência única, mais um sinal residual (LU *et al.*, 2018). Assim, o sinal original pode ser recuperado por meio da combinação linear:

$$x(t) = \sum_{n=1}^N imf_n(t) + r(t) \quad (19)$$

Um meio sistemático de obter *IMFs* consiste em um processo de peneirar (*sifting*) como é indicado abaixo (LI *et al.*, 2013): dado um sinal de entrada $x(t)$, $r(t) = x(t)$ e $n = 0$:

- Passo1 Obtenha o conjunto de máximos e o conjunto de mínimos locais de $x(t)$;
- Passo2 Obtenha o envoltório superior $e_{max}(t)$ conectando todos os máximos através de funções *splines* cúbicas. Repita o procedimento para conectar todos os mínimos locais e obtenha o envoltório inferior $e_{min}(t)$;
- Passo3 Calcule o valor médio para cada ponto dos envoltórios: $m(t) = (e_{max}(t) + e_{min}(t))/2$;
- Passo4 $h(t) = x(t) - m(t)$. Se $h(t)$ satisfaz as condições definidas anteriormente, então $n = n + 1$, $imf_n = h(t)$ e vá para o passo 5, caso contrário $x(t) = h(t)$ e retorne para o passo 1-4;
- Passo5 Seja $r(t) = r(t) - imf_n$. Se $r(t)$ é uma função monotônica encerre o processo de peneirar, caso contrário $x(t) = r(t)$ e retorne ao passo 1.

Conforme descrito em Huang *et al.* (1998), para garantir que cada *IMF* armazene informação suficiente para amplitude e frequência, é necessário estabelecer um critério de parada para o processo de peneirar. Isso pode ser realizado estabelecendo um valor de corte para o desvio padrão (DP), calculado a partir de duas iterações seguidas como:

$$DP = \sum_{t=1}^T \left[\frac{(h_1(k-1) - h_1(k))^2}{h_1^2(t)} \right] \quad (20)$$

3.1.5 Expoentes de Lyapunov

Os expoentes de Lyapunov têm se mostrado uma medida útil para distinguir entre os vários tipos de órbitas que podem ser produzidos por um determinado sistema dinâmico, com base na dependência dessas órbitas das condições iniciais do sistema. Desta forma, sistemas caóticos com dinâmica aperiódica podem ser adequadamente caracterizados pelo expoente de Lyapunov máximo e positivo, pois captura aquelas situações onde as trajetórias do espaço de fase têm estados iniciais quase idênticos e se separarão umas das outras em uma taxa exponencialmente crescente.

Considere dois pontos vizinhos no espaço de fase no instante 0 e no instante t (geralmente os mais próximos), sendo as distâncias dos pontos na i -ésima direção $\|\delta x_i(0)\|$ e $\|\delta x_i(t)\|$, respectivamente. O expoente de Lyapunov é então definido pela taxa média de crescimento λ_i da distância inicial dada pela equação 21.

$$\lambda_i(k) = \lim_{t \rightarrow \infty} \frac{1}{t} \log_2 \frac{\|\delta x_i(0)\|}{\|\delta x_i(t)\|} \quad (21)$$

Os expoentes de Lyapunov podem ser estimados a partir das equações de movimento do sistema dinâmico (se for conhecido) ou a partir da série temporal observada, que pode ser aplicado ao sinal de EEG. Para a última abordagem, os expoentes de Lyapunov podem ser extraídos de duas maneiras diferentes. O primeiro é baseado na ideia de seguir a evolução no tempo de pontos próximos no espaço de estados. Este método fornece uma estimativa apenas do maior expoente de Lyapunov. O segundo método é baseado na estimação de matrizes locais de Jacobianas, e é capaz de estimar todos os expoentes de Lyapunov (GüLER; ÜBEYLI; GüLER, 2005).

3.2 Algoritmos tradicionais de aprendizado de máquina

Para classificação do sinal, diferentes algoritmos podem ser aplicados nessa etapa do processo. Dentre esses classificadores, podemos destacar a Máquina de Vetores de Suporte (do inglês *Support Vector Machine* - SVM) e as Redes Neurais Artificiais (do inglês

Artificial Neural Network - ANN). Neste trabalho também será avaliado o emprego de Floresta de Caminhos Ótimos (do inglês *Optimum Path Forest* - OPF). A utilização de aprendizado profundo, com destaque para Redes Neurais Convolucionais, será discutida no capítulo 4.

3.2.1 Redes Neurais Artificiais

Uma rede neural artificial é uma máquina ou modelo computacional inspirado pela forma como o cérebro humano processa informações de maneira mais rápida que os atuais computadores digitais. Esse modelo é projetado para solucionar uma determinada tarefa de modo similar ao que o cérebro humano realiza uma atividade particular. Sua estrutura básica é denominada neurônio artificial, ou unidade de processamento, em analogia ao neurônio biológico. Utilizando o paradigma de aprendizado supervisionado, as forças de conexão entre os neurônios, ou peso sinápticos, armazenam o conhecimento adquirido do ambiente (HAYKIN, 2001). Nesse estudo é descrita uma rede neural que tem como unidade de processamento um neurônio do tipo *perceptron* que originou as redes neurais da classe Perceptrons de Múltiplas Camadas (do inglês *Multilayer Perceptron* - MLP).

Perceptron

O perceptron é um modelo de neurônio não-linear proposto por Frank Rosenblatt em 1958 (ROSENBLATT, 1958). A figura 7 mostra um modelo desse neurônio. A partir dessa representação podemos identificar três elementos fundamentais em sua constituição:

- 1) Um conjunto de sinapses, caracterizada pelos seus pesos. O sinal de entrada x_j está conectado à sinapse j ;
- 2) Um somador que atua como um combinador linear entre as entradas e seus respectivos pesos ponderadores;
- 3) Uma função de ativação ou função restritiva para limitar o valor do sinal de saída a um intervalo. Em geral, o intervalo adotado é o $[0, 1]$ ou ainda o $[-1, 1]$ (HAYKIN, 2001).

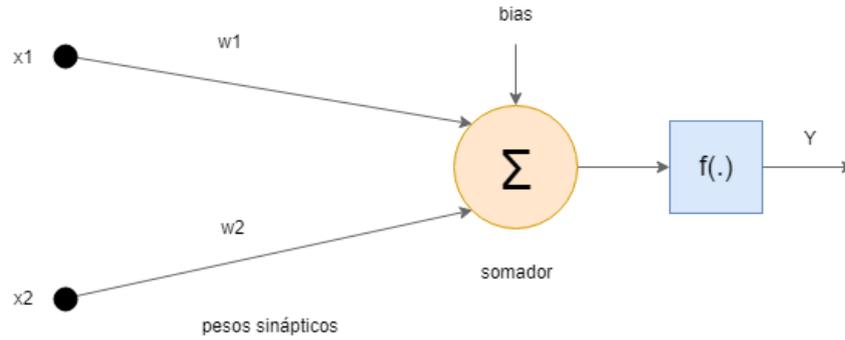


Figura 7 – Representação de um neurônio do tipo Perceptron

Fonte – Wallace Almeida, 2021

Além desses elementos fundamentais existe ainda um *bias* aplicado ao neurônio que impulsiona o valor da entrada da função de ativação. A saída do processamento do neurônio e entrada da função de ativação é dada pela equação 22 e, por sua vez, a saída dessa função é dada pela equação 23.

$$Z = \sum_i^m w_i x_i + b \quad (22)$$

$$Y = f(Z) \quad (23)$$

Perceptron de Múltiplas Camadas

As redes Perceptron de Múltiplas Camadas (*Multilayer Perceptron - MLP*) têm como unidade básica de processamento diversos neurônios do tipo perceptron, formando uma rede organizada em uma camada de entrada (unidades sensoriais), uma ou mais camadas ocultas e uma camada de saída (unidades computacionais) (HAYKIN, 2001). O sinal de entrada se propaga para frente, camada a camada (*feedforward*). Assim como no caso do perceptron isolado, cada um dos neurônios que constituem uma MLP apresentam um bias e uma função de ativação. Uma representação para esse tipo de rede é apresentada na figura 8.

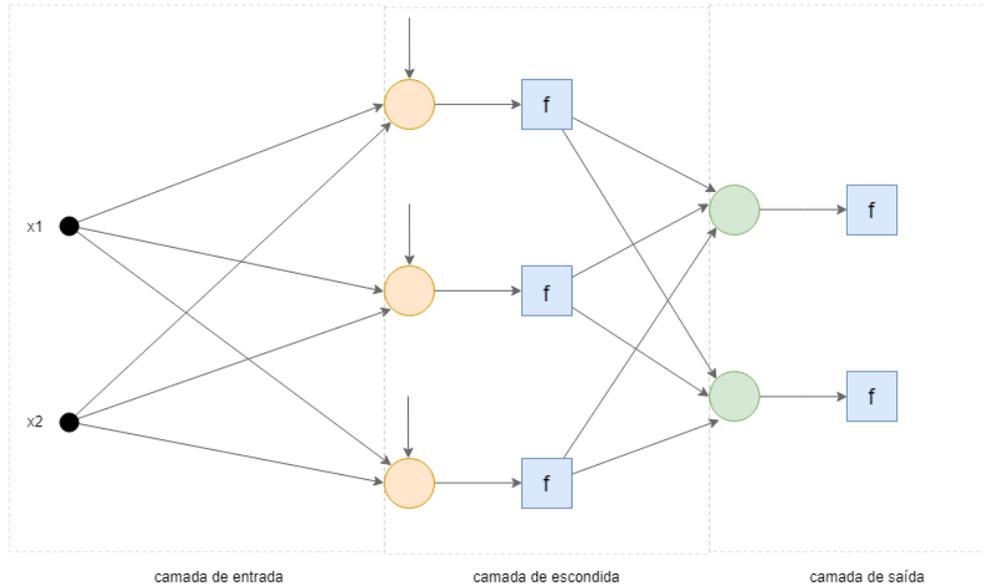


Figura 8 – Rede Neural do tipo MLP

Fonte – Wallace Almeida, 2021

Para treinamento de uma rede MLP, utiliza-se de modo geral o algoritmo de retropropagação do erro (*error backpropagation*). Seu princípio básico utiliza a diferença entre os valores esperados para os neurônios da camada de saída da rede e os valores efetivamente observados para atualizar os pesos sinápticos. O objetivo é reduzir essa diferença, aproximando os valores observados dos esperados.

De modo geral, a aprendizagem por retropropagação do erro consiste de dois passos: i) passo a frente, onde ocorre a propagação do sinal de entrada para frente e obtêm-se os valores observados de resposta; ii) passo para trás, onde os pesos sinápticos são ajustados de acordo com uma regra de correção do erro, com base na diferença entre os valores esperados e observados (HAYKIN, 2001).

Considerando o descrito em Haykin (2001), para um determinado neurônio j da camada de saída, tem-se que o erro associado a esse neurônio na apresentação da n -ésima instância de treinamento para a rede é definido pela equação 24, que representa a diferença entre o valor esperado para a saída do neurônio $d_j(n)$ e o valor obtido $y_j(n)$.

$$e_j(n) = d_j(n) - y_j(n) \quad (24)$$

Define-se o valor instantâneo do erro para o neurônio j como sendo $\frac{1}{2}e_j^2(n)$. Sendo assim, o valor instantâneo total do erro é dado pela soma dos valores instantâneos de erro para todos os neurônios existentes na camada de saída C , conforme a equação 25.

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (25)$$

Obtém-se o valor do erro quadrático médio somando o valor instantâneo total para cada amostra n , normalizando em relação ao tamanho N do conjunto de entrada, de acordo com a equação 26.

$$E_{med} = \frac{1}{N} \sum_{n=1}^N E(n) \quad (26)$$

A equação 26 representa a função de custo, medida do desempenho da aprendizagem, sendo o objetivo do treinamento minimizar o valor dessa função. A equação 27 representa a entrada do neurônio j da camada de saída, onde m representa o número de entradas (exceto o bias) e o peso $w_{j0} = b_j$ está relacionado ao *bias*.

$$Z_j(n) = \sum_{i=0}^m w_{ji}(n) y_i(n) \quad (27)$$

Por fim, a saída do neurônio j na n -ésima iteração, calculada pela função de ativação, é dada pela equação 28.

$$y_j(n) = \phi_j(Z_j(n)) \quad (28)$$

A correção $\delta w_{ji}(n)$ aplicada pelo algoritmo de retropropagação do erro é proporcional à derivada parcial $\frac{\partial E(n)}{\partial w_{ji}(n)}$, que pode ser expandida de acordo com a equação 29.

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial Z_j(n)} \frac{\partial Z_j(n)}{\partial w_{ji}(n)} \quad (29)$$

Derivando ambos os lados da equação 29, tem-se

$$\frac{\partial E(n)}{\partial e_j(n)} = e_j(n) \quad (30)$$

Seguindo para o próximo membro da equação, derivamos ambos os lados da equação 24 obtemos

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad (31)$$

Derivando ambos os lados da equação 28, tem-se

$$\frac{\partial y_j(n)}{\partial Z_j(n)} = \phi'_j(Z_j(n)) \quad (32)$$

Na equação 32 o ϕ'_j representa a derivada com relação ao argumento $Z_j(n)$. Assim, derivando a equação 27 com relação a $w_{ji}(n)$ tem-se

$$\frac{\partial Z_j(n)}{\partial w_{ji}(n)} = y_i(n) \quad (33)$$

Substituindo as equações 30 a 33 em 29 tem-se

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = -e_j(n)\phi'_j(Z_j(n))y_i(n) \quad (34)$$

Portanto, a correção a ser aplicada a $w_{ji}(n)$ é dada por

$$\Delta w_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)} \quad (35)$$

Na equação 35, η é a taxa de aprendizado adotada no algoritmo e o sinal negativo indica o gradiente descendente. Substituindo 34 nessa equação temos

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (36)$$

com o gradiente $\delta_j(n)$ definido como

$$\delta_j(n) = -\frac{\partial E(n)}{\partial v_j(n)} = -\frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial Z_j(n)} = e_j(n)\phi'_j(Z_j(n)) \quad (37)$$

3.2.2 Máquinas de Vetores Suporte

Máquinas de Vetores Suporte é um algoritmo de aprendizado de máquina baseado na teoria de aprendizado estatístico (CORTES; VAPNIK, 1995). Inicialmente desenvolvido para problema binário (separar duas classes), ele realiza a tarefa de classificação de dados em um espaço de alta dimensionalidade por estimar o melhor hiperplano, aquele de margem máxima, que divide as duas classes de maneira mais significativa (RAGHU; SRIRAAM, 2018). A figura 9 apresenta um conjunto linearmente separável em R^2 e os diferentes hiperplanos possíveis que dividem o conjunto.

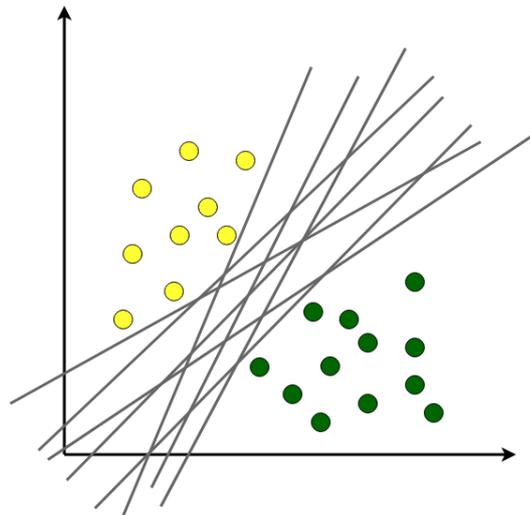


Figura 9 – Conjunto linearmente separável

Fonte – Wallace Almeida, 2021

Um dos principais fundamentos do algoritmo SVM é a restrição de utilização para apenas os vetores suporte localizados nas fronteiras entre as classes das instâncias de treinamento. O algoritmo SVM é capaz de ignorar *outliers* e calcular o hiperplano ótimo por meio da resolução de um problema de otimização restrito, utilizando hiperplanos de suporte. Na figura 10 é possível visualizar o hiperplano ótimo e os respectivos hiperplanos de suporte. Por meio das funções de *kernel*, o SVM é capaz de mapear os dados de entrada de um espaço de baixa dimensão para um espaço de alta dimensão, ou seja, converte um problema no qual os dados de entrada não são linearmente separáveis em um problema onde é possível obter dados linearmente separáveis (YUAN *et al.*, 2018).

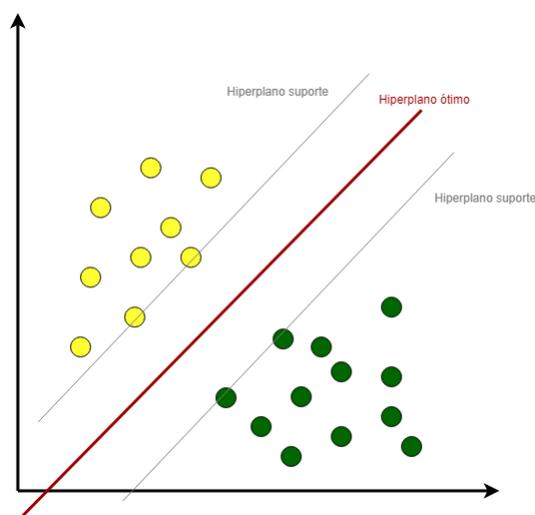


Figura 10 – Hiperplano ótimo e seus hiperplanos suporte

Fonte – Wallace Almeida, 2021

Conforme descrito em Lima (2004), em um comparativo com redes neurais, pelos propósitos do aprendizado estatístico, o SVM tende a apresentar uma maior capacidade de generalização, ou seja, um melhor desempenho frente aos dados de teste. Em virtude do princípio da minimização do risco estrutural (do inglês *Structural Risk Minimization* - *SRM*) aplicada na SVM, este pode ser superior a modelos baseados no princípio de minimização do risco empírico (do inglês *Empirical Risk Minimization* - *ERM*), o qual é aplicado no projeto de redes neurais. Para descrever a formulação do SVM, vamos considerar um problema envolvendo um conjunto de dados com duas classes linearmente separáveis definido por $(x_1, y_1), \dots, (x_n, y_n)$, com $x \in R^n$ e $y \in \{-1, 1\}$. A fronteira entre as duas classes no conjunto de dados é dada por um hiperplano definido como $(w \cdot x) + b = 0$, com $w \in R^n$ e $b \in R$

A margem de separação $\rho(w, b)$ é máxima quando a distância entre o hiperplano em relação a amostras mais próxima de cada uma das classes é máxima e tem distância igual entre elas. Assim as cada amostra x está sujeita à restrição (LIMA, 2004)

$$|(w \cdot x) + b| \geq \frac{\rho(w, b)}{2} \quad (38)$$

Fixando um valor para margem de separação $\rho(w, b) = 2$, a maximização da margem pode ser entendida como o problema de minimização da norma de w

$$\min_w |(w \cdot x) + b| = 1 \quad (39)$$

Como $y \in \{-1, 1\}$, logo, um hiperplano na forma canônica deve satisfazer as seguintes restrições para as amostras do treinamento

$$\begin{cases} (w \cdot x) + b \geq +1, \text{ para } y_i = +1, i = 1, \dots, N \\ (w \cdot x) + b \leq -1, \text{ para } y_i = -1, i = 1, \dots, N \end{cases} \quad (40)$$

As restrições na equação 40 podem ser descritas na forma

$$y_i [(w \cdot x) + b] \geq 1, \text{ com } i = 1, \dots, N \quad (41)$$

Considerando a distância de um vetor $x \in R^n$ à fronteira de decisão como sendo $d(w, b; x) = \frac{|(w \cdot x) + b|}{\|w\|}$, a margem de separação para as restrições na equação 41 é dada por

$$\begin{aligned}
\rho(w, b) &= \min_{\{x_i, y_i=1\}} d(w, b; x_i) + \min_{\{x_j, y_j=-1\}} d(w, b; x_j) \\
\rho(w, b) &= \min_{\{x_i, y_i=1\}} \frac{|(w \cdot x_i) + b|}{\|w\|} + \min_{\{x_j, y_j=-1\}} \frac{|(w \cdot x_j) + b|}{\|w\|} \\
\rho(w, b) &= \frac{1}{\|w\|} (\min_{\{x_i, y_i=1\}} |(w \cdot x_i) + b| + \min_{\{x_j, y_j=-1\}} |(w \cdot x_j) + b|) \\
\rho(w, b) &= \frac{2}{\|w\|}
\end{aligned} \tag{42}$$

Por fim, o hiperplano que separa otimamente os dados é tal que minimiza

$$\Phi(w) = \frac{1}{2} \|w\|^2 \tag{43}$$

A equação 43 e sua resolução com respeito à restrição na equação 41, além da discussão até o momento, parte da premissa que o problema tratado é linearmente separável. Nos cenários onde isso não ocorre a solução deve deixar de estar contida no espaço das amostras de treinamento e passa a utilizar o conceito de espaço de características (LIMA, 2004).

Para tratar os casos de problemas não linearmente separáveis, em Cortes e Vapnik (1995) foram introduzidas variáveis $\Xi_i \geq 0$, juntamente a uma função de custo de modo que o hiperplano que separa otimamente os dados passa a ser descrito por

$$\Phi(w, \Xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \Xi_i \tag{44}$$

sujeito às restrições

$$\begin{aligned}
\Xi_i &\geq 0 \\
y_i [(w \cdot x_i) + b] &\geq 1 - \Xi_i, \quad i = 1, \dots, N
\end{aligned} \tag{45}$$

onde o parâmetro C é um valor a ser definido pelo usuário da implementação do algoritmo.

3.2.3 Floresta de Caminhos Ótimos

A Floresta de Caminhos Ótimos é um classificador baseado em grafo, que tem como características a sua velocidade, simplicidade e independência de parâmetros. O OPF foi proposto inicialmente em Papa, Falcão e Suzuki (2009). O classificador modela um problema de reconhecimento de padrões como um grafo particionado em um espaço de características, no qual os nós representam os padrões. Adaptando ao cenário de processamento de sinais, os nós do grafo passam a representar um vetor de características

do sinal e as arestas passam a ter os pesos definidos pelas distâncias entre os vetores de características dos nós correspondentes. A distância mais comumente utilizada é Euclidiana (PAPA; FALCÃO; SUZUKI, 2009), dada por:

$$d(p, q) = \sqrt{\sum_{i_1}^n (p_i - q_i)^2} \quad (46)$$

A um caminho definido por instâncias distintas que conectam os nós terminais é atribuído um custo por meio de uma função de conectividade. Uma das possibilidades para essa função é a f_{max} definida a seguir

$$f_{max}(\langle s \rangle) = \begin{cases} 0 & \text{se } s \in S \\ +\infty & \text{caso contrário} \end{cases} \quad (47)$$

$$f_{max}(\pi.\langle s \rangle) = \max(f_{max}(\pi), d(s, t))$$

onde $d(s, t)$ é definida como a distância entre os vetores de características s e t , e um caminho π é definido como uma sequência de vetores de características adjacentes.

O objetivo é definir nós que representem cada uma das classes, denominados protótipos, de modo que cada instância seja atribuída à classe de seu protótipo mais fortemente conectado, ou seja que tenha caminho com custo mínimo até ele. Cada protótipo define uma árvore de caminhos ótimos (*Optimum Path Tree - OPT*) e o conjunto delas define uma OPF (PAPA; FALCÃO; SUZUKI, 2009).

Segundo Nunes *et al.* (2014), o classificador OPF pode ser entendido como uma generalização do reconhecido algoritmo de Dijkstra, que calcula caminhos ótimos em um grafo para todos os nós, a partir de um nó inicial. A principal diferença está relacionada à possibilidade de uso de múltiplos nós iniciais (os protótipos) e ao uso de uma função de custo genérica, que no caso do algoritmo de Dijkstra é definida como sendo a soma do peso das arestas.

O classificador OPF apresenta duas fases básicas e distintas entre si: i) treinamento e ii) classificação. A primeira fase consiste em encontrar os protótipos e calcular a OPF. A segunda fase é responsável por atribuir a uma característica do sinal de EEG da amostra de teste o rótulo de classe do protótipo mais fortemente conectado através da floresta de caminhos ótimos gerada durante o treinamento (NUNES *et al.*, 2014). A escolha ótima de protótipos pode ser realizada por meio do algoritmo de Árvore de Custos Mínimo (*Minimum Spanning Tree - MST*), por explorar a relação teórica entre ela e a OPF, uma vez que uma MST fornece um caminho entre dois nós de custo menor ou igual a qualquer

outro caminho possível. Representações das fases de treinamento e classificação estão destacadas nas figuras 11 a 14.

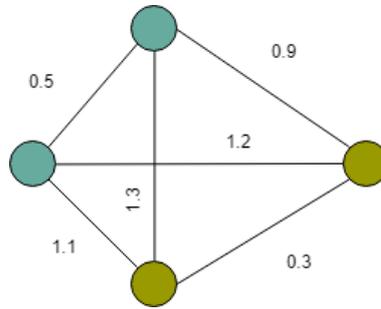


Figura 11 – Grafo completo

Fonte – Wallace Almeida, 2021

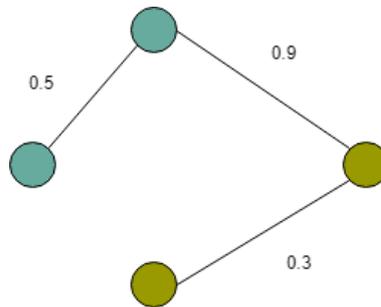


Figura 12 – Árvore de custo mínimo para a figura 11

Fonte – Wallace Almeida, 2021

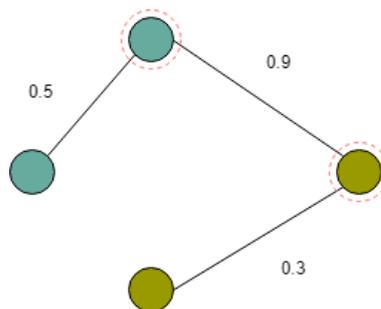


Figura 13 – Protótipos selecionados da figura 12

Fonte – Wallace Almeida, 2021

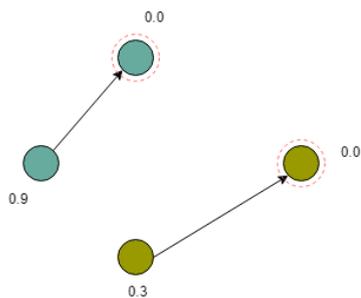


Figura 14 – Floresta de caminhos ótimos gerados no treinamento da figura 11

Fonte – Wallace Almeida, 2021

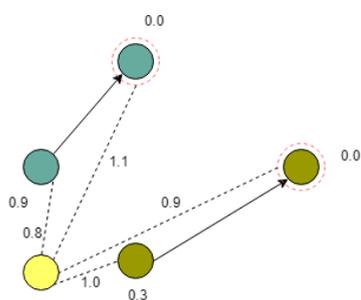


Figura 15 – Teste de uma nova instância para classificação

Fonte – Wallace Almeida, 2021

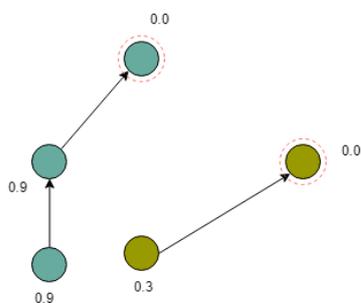


Figura 16 – Amostra classificada pela função de conectividade da figura 11

Fonte – Wallace Almeida, 2021

4 Aprendizado profundo para classificação de sinais de EEG

O aprendizado profundo (do inglês *Deep Learning* - DL) refere-se a um conjunto de técnicas relacionadas a redes neurais com múltiplas camadas. A popularidade recente do DL é decorrente de diversos fatores, como por exemplo o desenvolvimento de abordagens bem-sucedidas para diferentes tarefas relacionados ao processamento de imagens e textos. Como exemplo de arquiteturas dessa técnicas estão as redes neurais convolucionais (KHAMPARIA; SINGH, 2019).

4.1 Redes Neurais Convolucionais

Uma Rede Neural Convolucional (do inglês *Convolutional Neural Network* - CNN) é um modelo de rede neural constituída por diversas camadas dispostas de modo hierárquico, inspirada no sistema visual dos mamíferos, com diversas aplicações na área de visão computacional (KHAMPARIA; SINGH, 2019).

As CNNs são consideradas uma das técnicas mais conhecidas de aprendizado profundo que envolve o treinamento das diversas camadas, combinando a etapa de extração de características e classificação. Uma das principais diferenças comparadas aos algoritmos tradicionais é que uma rede CNN aprende a extrair características e classificar de modo direto, em vez de realizar essas etapas de modo separado. Assim, não é necessária a construção de características de modo manual.

Cada uma dessas camadas que compõem uma CNN tem o objetivo específico de processar as informações recebidas da camada anterior. As camadas ocultas são responsáveis pela detecção e extração do características usando uma série de procedimentos de convolução e subamostragem (*pooling*), visando a redução da dimensionalidade. Essas camadas de convolução e subamostragem, que constituem as camadas escondidas, são dispostas sequencialmente aos pares para obter características de alto nível (CHAUDHARY *et al.*, 2019).

Grande parte da literatura disponível para CNNs aborda dados de entrada em duas dimensões, sendo fundamentalmente aplicadas em problemas que envolvem reconhecimento de imagens (CRAIK; HE; CONTRERAS-VIDAL, 2019). Em geral, as CNNs apresentam boas performances em diversas tarefas de reconhecimento, como reconhecimento de texto

escrito à mão, reconhecimento de face, classificação de sinais de trânsito, detecção de pedestres, atribuição de rótulos a imagens e etc. A figura 17 ilustra a arquitetura de uma CNN.

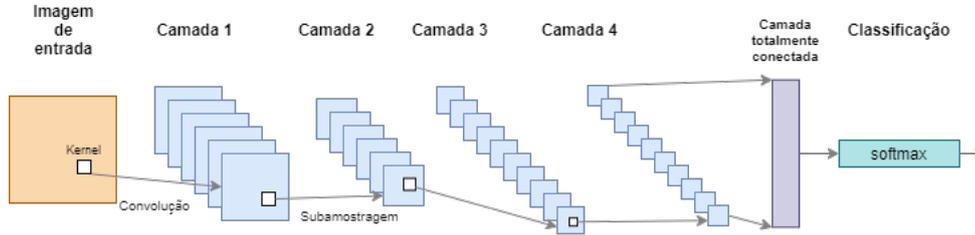


Figura 17 – Exemplo de uma Rede Neural Convolutiva

Fonte – Wallace Almeida, 2021

4.1.1 Camada de convolução

A camada de convolução é composta por uma série de filtros, também conhecidos como máscaras ou *kernels*, cujos coeficientes são ajustados durante o processo de treinamento. Com um número fixo de filtros em cada camada, cada filtro individual recebe uma convolução transversalmente com a largura e a altura da imagem de entrada nas transmissões para frente. Considerando uma matriz I_e de duas dimensões e um *kernel* de duas dimensões k centrado na posição de índice $[0,0]$, a equação 48 apresenta a operação de convolução, ilustrada na figura 18. A saída dessa camada é um mapa de características bidimensional daquele filtro para detectar um padrão.

$$I_s(i, j) = I_e \otimes K = \sum_{k=1}^N \sum_{l=1}^M I_e(k, l)K(i - k, j - l) \quad (48)$$

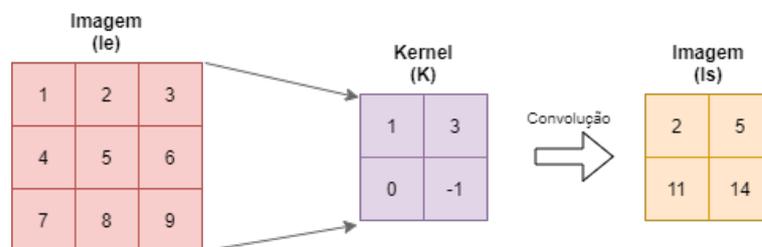


Figura 18 – Exemplo de convolução discreta em duas dimensões

Fonte – Wallace Almeida, 2021

Uma rede neural pode sofrer um efeito conhecido como sobre-ajuste (do inglês *overfitting*), no qual a rede treinada se torna incapaz de classificar adequadamente amostras

inéditas, ou seja, apresenta uma baixa capacidade de generalização. Um mecanismo para minimizar este efeito é inserir um termo de regularização na função custo. Uma forma de regularização muito utilizada nas CNNs é chamada de *dropout*. Essa técnica consiste em desligar a ativação de neurônios de modo independente, com uma probabilidade pré-estabelecida. Essencialmente, o *dropout* oferece uma maneira eficiente de reduzir o tamanho e a complexidade da rede, tornando mais rápida e efetiva a etapa de treinamento (ROY *et al.*, 2019). A figura 19 ilustra a aplicação da técnica de *dropout*.

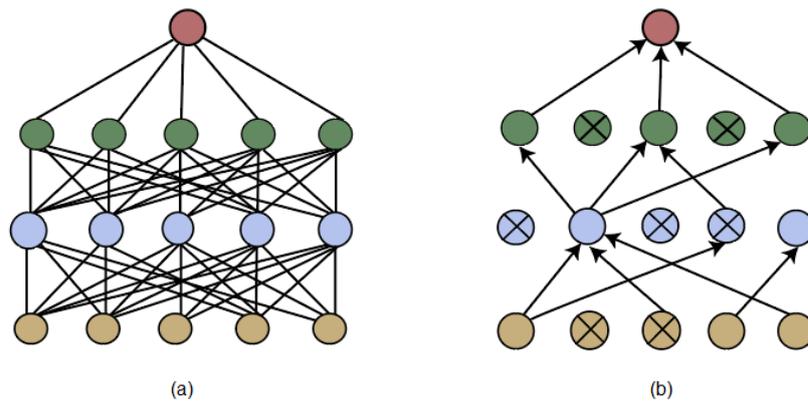


Figura 19 – Exemplo de uma Rede Neural antes (a) e após aplicação de *dropout* (b)

Fonte – Adaptado de Srivastava *et al.* (2014)

Um outro problema comum nas CNNs é o desvanecimento do gradiente, ou seja, a medida que o gradiente da função custo é retro-propagada para trás o valor do gradiente tende para zero. Para evitar este problema utilizam-se outras funções de ativação. A função de ativação aplicada mais frequentemente é a unidade linear retificada (do inglês *Rectified Linear Unit* - ReLU), conforme destacado em Craik, He e Contreras-Vidal (2019). A função ReLU é apresentada na equação 49.

$$f(x) = \max(0, x) \quad (49)$$

A segunda função de ativação mais aplicada é a unidade linear exponencial (do inglês *Exponential Linear Unit* - ELU), uma variação da ReLU com melhores resultados para saídas negativas da rede, controladas pelo hiper-parâmetro α (CRAIK; HE; CONTRERAS-VIDAL, 2019). A equação 50 apresenta a função ELU.

$$f(x) = \begin{cases} \alpha(e^x - 1) & \text{se } x \leq 0 \\ x & \text{se } x > 0 \end{cases} \quad (50)$$

4.1.2 Camada de subamostragem

Subsequente à camada de convolução tem-se a camada de subamostragem, cujo principal objetivo é a redução da dimensionalidade do mapa de características e dos parâmetros da rede, enquanto armazena informações relevantes. Ela cria uma amostragem não linear, mesclando valores próximos no espaço de características por meio de vários operadores. O número de parâmetros e, portanto, o cálculo na rede, é reduzido, minimizando o tamanho do espaço de entrada, permitindo que a rede seja mais profunda. Essa camada é invariável à rotação e pode evitar o sobre-ajuste. Essas camadas ocultas são sucedidas por uma camada totalmente conectada que atua como o classificador das características extraídas anteriormente. O processo de subamostragem usando o operador de máximo, conhecido como *maxpooling*, é apresentado na equação 51 e ilustrado pela figura 20.

$$Sub(i, j) = \sum_{k=1}^N \sum_{l=1}^M \max(I_c(k, l)Mask(i - k, j - l)) \quad (51)$$

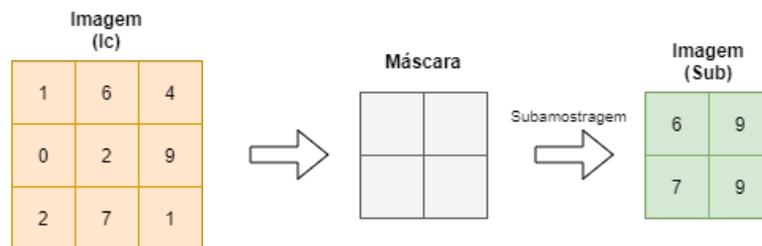


Figura 20 – Exemplo de operação de subamostragem usando o operador máximo

Fonte – Wallace Almeida, 2021

4.1.3 Camada de classificação - camada totalmente conectada

A camada de classificação alimenta a rede neural, convertendo o mapa de características 2D em um vetor de características 1D. Nessa camada, é calculado o erro durante o treinamento que é então retropropagado de modo que todos os pesos da CNN sejam atualizados. Para minimização do erro, métodos baseados em descida de gradiente são geralmente utilizados. Na camada de saída é geralmente adotada a função de ativação *softmax*, que converte a saída em probabilidade. Por fim, a camada de classificação aloca uma classe ou categoria provável para o dado de entrada com base nessa função (CHAUDHARY *et al.*, 2019).

4.2 Representação de um sinal 1D em 2D

Por sua forma de construção e resultados alcançados, as CNNs têm sido aplicadas de modo mais comum para reconhecimento de padrões em imagens. Ou seja, utilizam como dados de entrada uma estrutura de duas dimensões (2D) (KHAMPARIA; SINGH, 2019). Em sua representação convencional, os sinais de EEG são unidimensionais (1D). Desse modo, em geral, para uma aplicação direta desse algoritmo de aprendizado profundo, é necessária uma mudança na representação do sinal.

Em alguns estudos, o sinal de EEG foi convertido em mapas topográficos e imagens para utilização de CNNs, uma vez que esses modelos assumem que as entradas são 2D. No entanto, essa conversão corre o risco de perder informações e recursos importantes. Em virtude do EEG apresentar correlação ao longo do tempo, nesse contexto, é desejável o uso dos dados brutos de EEG, a fim de extrair e aprender características genéricas.

Várias tentativas foram feitas para extrair representações de imagens 2D de sinais brutos 1D para resolver uma tarefa de classificação de série temporal com CNNs. As técnicas de representação em tempo-frequência nos permitem representar os sinais 1D de EEG como imagens 2D. Dentre elas, um método comum é o uso algoritmo de Transformada de Fourier de Curto Tempo (*Short-Time Fourier Transform* - STFT), que traduz os sinais do domínio do tempo em sinais do domínio de tempo-frequência (CHAUDHARY *et al.*, 2019). O STFT produz uma única imagem de espectrograma de domínio de frequência de tempo 2D para cada eletrodo do sinal de EEG. Assim, se temos sinais de EEG de N eletrodos, então N imagens de espectrograma 2D podem ser geradas. Essas imagens são então alimentadas na CNN para extração de características e classificação do sinal (HA; JEONG, 2019).

Recentemente, a CNN alcançou bom desempenho para dados de EEG representados como entrada 2D, com amostras representando os dados capturados ao longo do tempo. Em geral, quando c canais são coletados e uma janela tem amostras de comprimento l , a entrada de uma rede neural para o processamento EEG consiste em um vetor $X_i \in R^{c \times l}$ contendo as l amostras correspondentes a uma janela para todos os canais. Esta matriz bidimensional pode ser usada diretamente como um exemplo para treinar uma rede convolutiva (ROY *et al.*, 2019).

5 Experimentos e resultados

Neste capítulo são descritos o conjunto de dados, os experimentos e os resultados obtidos para classificação do sinal de EEG para as quatro tarefas de MI abordadas, movimento da mão esquerda, mão direita, pés e língua. As técnicas de extração de características utilizadas foram CSP, dimensões fractais de Katz e Higuchi, DWT, EMD e expoentes de Lyapunov, as quais foram implementadas conforme descrito na seção 3.1. Como técnicas adicionais, foram incluídas as estatísticas raiz quadrada média (do inglês *Root Mean Square* - RMS) e valor absoluto integrado (do inglês *Integrated Absolute Value* - IAV), que foram aplicadas anteriormente em sinais de eletromiograma (EMG) (PHINYOMARK; LIMSAKUL; PHUKPATTARANONT, 2009). Os algoritmos tradicionais de aprendizado de máquina utilizados para a classificação foram SVM, MLP e OPF, os quais foram descritos na seção 3.2. Além disso, foram utilizadas redes neurais convolucionais, descritas no capítulo 4.

5.1 Conjunto de dados

O conjunto de dados selecionado para treinamento e validação dos métodos propostos foi o conjunto 2a da Quarta Competição de Interface Cérebro-Computador de 2008. Os dados foram coletados pelos pesquisadores da Universidade de Graz na Áustria (TANGERMANN *et al.*, 2012), e disponibilizados publicamente no site da competição (<http://www.bbc.de/competition/iv/>). A competição de BCI é um desafio aberto que visa avaliar diferentes abordagens para interfaces cérebro-computador e compará-las no mesmo conjunto de dados, a fim de obter uma métrica confiável de desempenho para cada algoritmo. O objetivo dos competidores é fornecer algoritmos capazes de classificar corretamente os dados do conjunto de teste.

Os dados referem-se a informações de imagéticas motoras em sinais de EEG para 9 indivíduos. Esse conjunto apresenta 4 diferentes tarefas de intenção de movimento. A classe 1 corresponde ao movimento da mão esquerda, a classe 2 ao movimento da mão direita, a classe 3 ao movimento de ambos os pés e a classe 4 ao movimento da língua. Os dados foram capturados em duas sessões usando 22 eletrodos dispostos no couro cabeludo. Cada sessão totaliza 288 ensaios, divididos igualmente entre cada uma das quatro classes.

A frequência de amostragem é de 250 Hz, com os dados filtrados na faixa de frequência de 0,5 a 100 Hz. Em virtude da interferência da frequência da energia elétrica, foi aplicado um filtro do tipo notch em uma frequência de 50 Hz (frequência da rede elétrica na Europa) para remoção desse artefato.

Para os ensaios, os indivíduos foram colocados em frente a uma tela. No início de um ensaio ($t = 0s$), uma cruz de fixação aparecia na tela preta e um curto aviso sonoro era disparado. Após $t = 2s$ aparecia uma seta apontando para a esquerda, direita, para baixo ou para cima, correspondendo a cada uma das quatro classes, e permanecia na tela por 1,25 s. Nesse momento os indivíduos deveriam realizar a tarefa de imagética motora desejada até que a cruz de fixação desaparecesse da tela ($t = 6 s$). Em seguida ocorria uma pequena pausa, na qual a tela ficava preta novamente até o próximo estímulo. A figura 21 ilustra esta configuração.

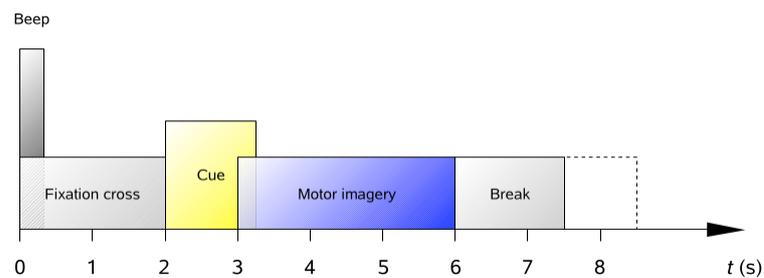


Figura 21 – Disposição dos eventos em cada ensaio do conjunto de dados

Fonte – [Tangermann et al. \(2012\)](#)

5.2 Etapas de pré-processamento e estratégias de treinamento

Foram definidas duas abordagens para execução dos experimentos utilizando técnicas tradicionais de aprendizado de máquina e três abordagens para CNNs, levando em consideração que o sinal de EEG apresenta eventos relacionados à MI fundamentalmente nas faixas de frequência mu e beta.

A primeira abordagem utiliza para todas as características uma divisão em 4 faixas de frequência, similar ao proposto exclusivamente para os CSP em [Khan et al. \(2020\)](#). Essa estratégia foi estendida para as demais características. A faixa 1 corresponde ao intervalo da faixa mu entre 7 e 13 Hz. As faixas 2, 3 e 4 correspondem a subdivisões da faixa beta, contemplando os intervalos entre 13 e 19 Hz, 19 e 25 Hz e 25 e 31 Hz respectivamente. Nessa abordagem, para todos os indivíduos, foi considerada uma janela entre 4 e 5 s para

a etapa de treinamento e entre 2,5 e 3 s para etapa de teste. A figura 22 apresenta um diagrama que exemplifica essa abordagem.

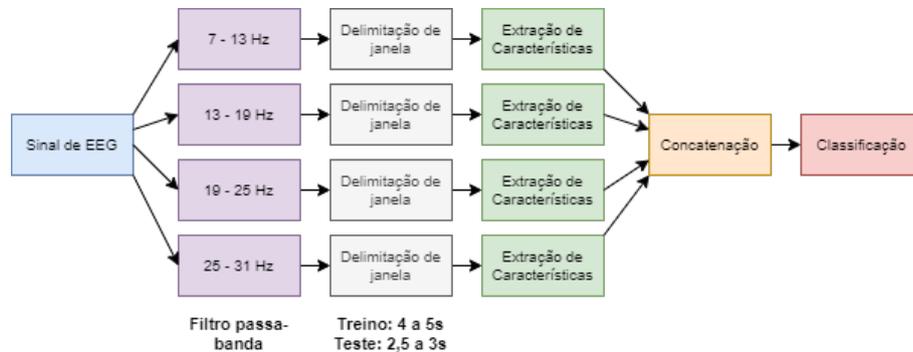


Figura 22 – Abordagem #1 para classificação do sinal de EEG

Fonte – Wallace Almeida, 2021

A segunda abordagem, uma adaptação para o cenário de múltiplas classes da proposta descrita em [Selim et al. \(2020\)](#), utiliza um filtro passa-faixa entre 10 e 30Hz para todos os indivíduos. Neste caso, denominado de variação 1, a janela foi delimitada entre o intervalo 2,5 e 5,5 s para as etapas de treinamento e teste. Para efeitos de comparação e validação da influência das escolhas das faixas de frequência e da janela do sinal, foram acrescentadas mais duas variações para essa abordagem. A variação 2 não aplica a restrição de janela, considerando o intervalo entre 2 e 6 do sinal para treinamento e teste, porém mantém a faixa de frequência da primeira. A variação 3 não aplica a restrição de janela, novamente considerando o intervalo entre 2 e 6 do sinal para treinamento e teste, e considera a faixa de frequência entre 0,5 e 40 Hz, contemplando todos os ritmos oscilatórios. A abordagem proposta está representada na figura 23.

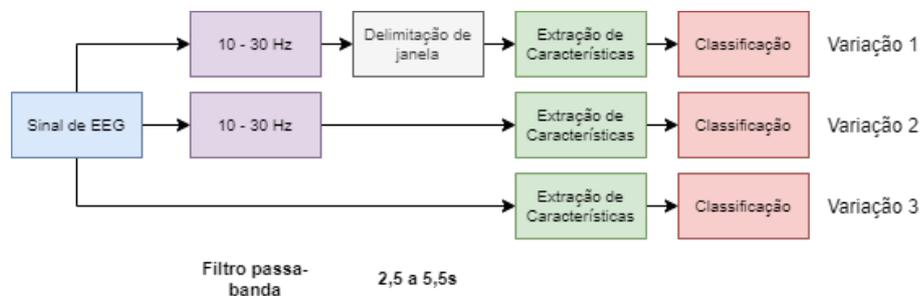


Figura 23 – Abordagem #2 para classificação do sinal de EEG

Fonte – Wallace Almeida, 2021

A estratégia com uma divisão do sinal em 4 faixas de frequência, similar ao realizado na abordagem #1 das técnicas tradicionais, foi empregada para compor a primeira abordagem com técnicas de DL, conforme ilustrado na figura 24.

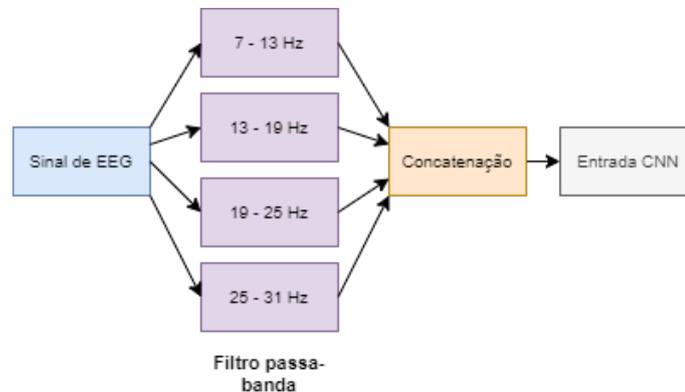


Figura 24 – Abordagem #1 para classificação do sinal de EEG com CNN

Fonte – Wallace Almeida, 2021

A segunda abordagem utiliza sobre o sinal bruto uma estratégia para a faixa de frequência e restrição de janela semelhante ao adotado na variação 3 da segunda abordagem para as técnicas tradicionais. Ou seja, um intervalo entre 2 e 6 s do sinal para os ensaios de treinamento e teste, e faixa de frequência entre 0,5 e 40 Hz. A figura 25 representa esta abordagem.

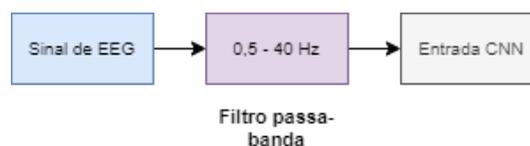


Figura 25 – Abordagem #2 para classificação do sinal de EEG com CNN

Fonte – Wallace Almeida, 2021

Para a terceira abordagem envolvendo CNN, foi empregada uma estratégia de treinamento por *crops*, descrita em Schirrmeister *et al.* (2017). Essa estratégia utiliza como entrada os recortes obtidos por meio de uma janela deslizante dentro de cada ensaio, o que produz um número muito maior de dados de treinamento. A inspiração para essa estratégia vem do treinamento das CNNs para reconhecimento de imagens, onde são empregados diferentes recortes de uma mesma imagem como dados de entrada, a fim de aumentar a performance da classificação. Nesta terceira abordagem, a intenção foi produzir o maior número de *crops* possível, com um tamanho de janela de 2 s. O primeiro *crop* construído iniciou 0,5 s antes do aparecimento da seta representando uma das quatro classes. A janela

desliza uma única amostra em cada passo e o último *crop* termina no instante $t = 6$ s. Considerando que a frequência de amostragem é de 250 Hz, esse processo resultou em 625 *crops*, com 500 amostras cada. Cada um deles é um novo dado de treinamento, que recebeu a mesma classe atribuída ao ensaio original. A figura 26 ilustra o processo da janela deslizante.

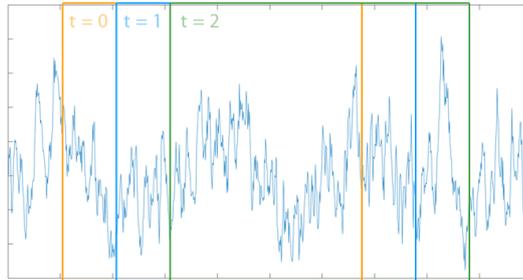


Figura 26 – Janela deslizante sobre o sinal de EEG e criação de *crops*

Fonte – Wallace Almeida, 2021

5.3 Configuração dos experimentos

Na estratégia envolvendo os algoritmos tradicionais, as técnicas de extração de características e os classificadores foram desenvolvidos usando o software Matlab, utilizando uma combinação de implementações próprias, funcionalidades pré-disponibilizadas na plataforma e bibliotecas auxiliares.

Com relação ao extrator de característica EMD, com base em experimentos preliminares, foram identificadas três IMFs como o maior número em comum para todos os canais envolvendo todos ensaios de treinamento e teste do conjunto de dados. Sendo assim, para o EMD, o número de IMFs geradas foi fixado igual a 3. No caso da DWT, utiliza-se 2 níveis de decomposição, empregando os coeficientes A2 extraídos com a função mãe Daubechies de ordem quatro (Db4). Para o método de dimensão fractal de Higuchi, foi adotado 10 como número máximo de subsequências.

Com respeito aos parâmetros e configurações dos classificadores, para a SVM foi utilizada uma implementação para múltiplas classe do tipo C-SVC, cujo kernel adotado foi a função de base radial (do inglês *Radial Base Function* - RBF), parâmetro C foi fixado em 100 e o parâmetro γ (inverso do desvio padrão da RBF) foi escolhido dentre o conjunto de valores formado por $2e^k$, com $k = -2, -1, 0, 1, 2$. Para a MLP, foi adotada a função de ativação sigmoide e utiliza-se 1000 épocas ou erro menor que 10^{-5} como condição de

parada para o treinamento. O número de neurônios para a camada escondida foi escolhido dentre os valores 10, 20, 50, 100 e 150. Para o OPF, a métrica de distância escolhida foi a Euclidiana. Os resultados apresentados a seguir correspondem ao da configuração que apresentou a melhor performance.

Para as abordagem envolvendo CNN, foram implementados modelos de CNN inspirados na arquitetura AlexNet (KRIZHEVSKY; SUTSKEVER; HINTON, 2012) e baseados nos modelos descritos em Amin *et al.* (2019). No total, foram investigados quatro modelos diferentes, denominados CNN1, CNN2, CNN3 e CNN4. Estas CNNs foram implementadas utilizando uma combinação das bibliotecas Keras e TensorFlow. Uma representação para o número de camadas de convolução e subamostragem da CNN4 é mostrado na figura 27. Os detalhes relacionados ao número de filtros e suas dimensões, o parâmetro de deslocamento (do inglês *strider*) e as configurações das camadas são fornecidos na tabela 3. O valor para *dropout* foi adotado igual a 0,5 e o número de épocas fixado em 60 (este valor foi definido com base em experimentos preliminares). Como função de ativação foi utilizada a função ELU, o algoritmo Adam foi utilizado para otimização, e a entropia cruzada aplicada como função de custo.



Figura 27 – Modelos implementado para CNN4

Fonte – Wallace Almeida, 2021

Para os modelos apresentados, a primeira operação de convolução é segmentada em duas partes. A primeira operação de convolução é realizada em cada canal em algumas amostras ao longo do tempo. A segunda convolução é realizada para todos os canais simultaneamente, uma amostra por vez. Essa configuração contempla uma das estratégias de representação em 2D para o sinal de EEG e permite manipular entradas de múltiplos canais. Essa convolução é representada na figura 28

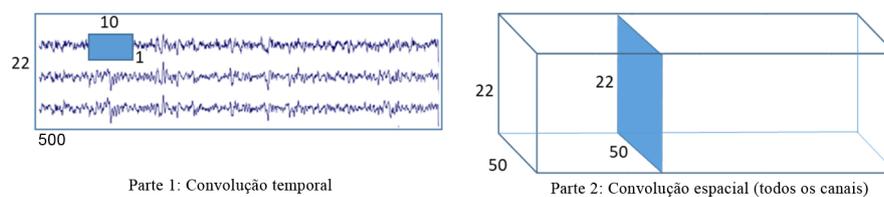


Figura 28 – Convolução em duas etapas: temporal e espacial

Fonte – Adaptado de Amin *et al.* (2019)

Tabela 3 – Estrutura dos modelos de CNN

Modelo	Configuração	Modelo	Configuração
CNN-1	Conv (30 x 1, 50 filtros)	CNN-2	Conv (25 x 1, 50 filtros)
	Conv (1 x 22, 50 filtros)		Conv (1 x 22, 50 filtros)
	Max Pool (3 x 1, strider 3)		Max Pool (3 x 1, strider 3)
	Dense (1024)		Conv (10 x 1, 100 filtros)
	Softmax (4 classes)		Max Pool (3 x 1, strider 3)
			Dense (1024)
			Softmax (4 classes)
CNN-3	Conv (20 x 1, 50 filtros)	CNN-4	Conv (10 x 1, 50 filtros)
	Conv (1 x 22, 50 filtros)		Conv (1 x 22, 50 filtros)
	Max Pool (3 x 1, strider 3)		Max Pool (3 x 1, strider 3)
	Conv (10 x 1, 100 filtros)		Conv (10 x 1, 100 filtros)
	Max Pool (3 x 1, strider 3)		Max Pool (3 x 1, strider 3)
	Conv (10 x 1, 100 filtros)		Conv (10 x 1, 100 filtros)
	Max Pool (3 x 1, strider 3)		Max Pool (3 x 1, strider 3)
	Dense (1024)		Conv (10 x 1, 200 filtros)
Softmax (4 classes)	Max Pool (3 x 1, strider 3)		
			Dense (1024)
			Softmax (4 classes)

Fonte – Wallace Almeida, 2021

Cada uma das CNNs apresenta uma extensa quantidade de parâmetros, que são ajustados durante a etapa de treinamento. Conforme a rede apresenta um número maior de camadas de convolução e subamostragem, a quantidade de parâmetros diminui em razão das operações de *dropout*. A quantidade de parâmetros é exibida na tabela 4.

Tabela 4 – Quantidade de parâmetros nos modelos de CNN

Modelo	Treináveis	Não-treináveis	Total
CNN1	16.601.266	1.942	16.603.208
CNN2	10.866.158	2.584	10.868.742
CNN3	3.491.016	2.792	3.493.808
CNN4	1.847.590	2.866	1.850.456

Fonte – Wallace Almeida, 2021

5.4 Resultados

Esta seção descreve os resultados dos experimentos realizados para as técnicas tradicionais e aprendizado profundo, considerando as abordagens descritas na seção 5.3. A influência da escolha das faixas de frequência e da janela obtidas do sinal para as técnicas tradicionais também são detalhadas. Por fim, são descritos os resultados obtidos para

as diferentes arquiteturas de CNN, comparando as performances obtidas para as três abordagens de treinamento descritas para esses modelos.

A condução dos experimentos utilizou o protocolo descrito na base de dados, que consiste em utilizar a primeira sessão de cada indivíduo para treinamento e a segunda sessão para teste, com 288 ensaios cada. A estratégia que faz uso de *crops* aumenta os dados de treinamento e teste de cada ensaio de acordo com número de recortes criados. Neste experimento, foram gerados 180.000 instâncias. Já na abordagem que utiliza a segmentação do sinal em quatro faixas de frequência para as CNNs, foram geradas 1.152 instâncias, multiplicando por quatro a quantidade original de dados de entrada.

As tabelas 5, 6 e 7 apresentam os resultados obtidos para a abordagem #1. Como pode-se observar, o CSP extraiu características com propriedades mais discriminantes para essa abordagem. Em um cenário com janelas pequenas para treinamento e teste, a concatenação das características obtidas a partir de cada faixa de frequência alcançou uma acurácia média superior a 80% para os classificadores SVM e MLP. O OPF alcançou um desempenho de 68%, um pouco menor que o alcançado pelo SVM e MLP. Ao utilizar as características extraídas pelos métodos de Higuchi e Katz, foi obtida uma acurácia média inferior, ou muito próxima, a de um classificador "aleatório" para um problema envolvendo 4 classes em um conjunto de dados balanceado, ou seja 25%. O expoente de Lyapunov não forneceu uma propriedade discriminante para os classificadores, tendo como resultado de classificação uma única classe, e uma acurácia correspondente a 25%. Por fim, as características estatísticas RMS e IAV apresentaram melhores resultados em relação às demais, exceto com relação ao CSP, porém com médias inferiores a 50%. Por se tratar de uma análise sobre pequenas faixas de frequência combinadas, para essa abordagem não foram aplicadas as técnicas DWT e EMD. Existem indivíduos, como por exemplo o s2 e s6, que possuem resultados inferiores em relação aos demais. Isto exemplifica os desafios levantados anteriormente para os sistemas de BCI, como as possíveis variações significativas de desempenho entre indivíduos distintos, ou leituras não uniformes para o sinal em diferentes sessões para um mesmo indivíduo.

Nas tabelas 8 a 16 são apresentados os resultados das três variações propostas para a abordagem #2, com a utilização das mesmas técnicas de extração de características da abordagem anterior e com a inclusão das técnicas DWT e EMD. Por meio dessa abordagem, é possível discutir as variações de performance dos classificadores em relação à restrição de janela e faixas de frequência. Para a variação 1, representada nas tabelas

Tabela 5 – Resultados utilizando o classificador SVM - abordagem #1

Indivíduo	Higuchi	Katz	RMS	IAV	Lyapunov	CSP
s1	0,27	0,34	0,30	0,36	0,25	0,82
s2	0,26	0,26	0,28	0,26	0,25	0,73
s3	0,26	0,27	0,51	0,53	0,25	0,84
s4	0,26	0,28	0,42	0,43	0,25	0,84
s5	0,29	0,26	0,28	0,27	0,25	0,78
s6	0,27	0,23	0,39	0,38	0,25	0,73
s7	0,27	0,26	0,55	0,53	0,25	0,86
s8	0,27	0,30	0,42	0,46	0,25	0,88
s9	0,26	0,24	0,55	0,56	0,25	0,87
Média	0,27	0,27	0,41	0,42	0,25	0,82

Fonte – Wallace Almeida, 2021

Tabela 6 – Resultados utilizando o classificador MLP - abordagem #1

Indivíduo	Higuchi	Katz	RMS	IAV	Lyapunov	CSP
s1	0,30	0,31	0,50	0,47	0,24	0,81
s2	0,23	0,30	0,28	0,33	0,21	0,72
s3	0,26	0,30	0,59	0,67	0,28	0,84
s4	0,26	0,24	0,46	0,50	0,22	0,83
s5	0,27	0,26	0,27	0,28	0,23	0,75
s6	0,25	0,28	0,42	0,37	0,26	0,71
s7	0,27	0,28	0,61	0,60	0,21	0,87
s8	0,23	0,26	0,57	0,48	0,23	0,88
s9	0,31	0,32	0,49	0,47	0,25	0,86
Média	0,26	0,28	0,47	0,46	0,24	0,81

Fonte – Wallace Almeida, 2021

Tabela 7 – Resultados utilizando o classificador OPF - abordagem #1

Indivíduo	Higuchi	Katz	RMS	IAV	Lyapunov	CSP
s1	0,26	0,29	0,33	0,32	0,23	0,69
s2	0,26	0,24	0,25	0,24	0,27	0,59
s3	0,29	0,28	0,36	0,38	0,21	0,70
s4	0,25	0,24	0,30	0,33	0,22	0,69
s5	0,27	0,25	0,28	0,26	0,24	0,60
s6	0,23	0,27	0,33	0,33	0,26	0,55
s7	0,32	0,29	0,34	0,32	0,27	0,78
s8	0,28	0,29	0,35	0,34	0,23	0,73
s9	0,25	0,34	0,37	0,40	0,25	0,76
Média	0,27	0,28	0,32	0,32	0,24	0,68

Fonte – Wallace Almeida, 2021

8, 9 e 10, o CSP destaca-se como a técnica que extrai características com alto poder discriminatório, com acurácia média próxima a 70% para o SVM, MLP e OPF. Esses valores são inferiores em relação aos obtidos na abordagem #1. Para a técnica que utiliza os coeficientes wavelet como características, nota-se um baixo desempenho para essa tarefa. A técnica que utiliza as funções intrínsecas da EMD apresentou um desempenho similar à DWT. As técnicas de dimensão fractal também apresentaram baixo desempenho, porém ligeiramente superior às duas técnicas anteriores. Mesmo sem atribuir uma única classe às predições, o expoente de Lyapunov novamente não forneceu um conjunto de características discriminatório, e conseqüentemente os classificadores não obtiveram boa performance. Já as características estatísticas via RMS e IAV apresentaram ganhos de desempenho em comparação à abordagem #1, aproximando a acurácia média do valor de 50%. Por fim, as técnicas de dimensão fractal apresentaram uma maior evolução relativa no desempenho comparado ao método anterior, atingindo acurácia média próxima à observada nas características estatísticas.

Tabela 8 – Resultados utilizando o classificador SVM - abordagem #2 - variação 1

Indivíduo	Higuchi	Katz	RMS	IAV	DWT	EMD	Lyapunov	CSP
s1	0,50	0,36	0,52	0,50	0,25	0,25	0,25	0,81
s2	0,32	0,25	0,26	0,24	0,25	0,25	0,26	0,57
s3	0,56	0,50	0,63	0,66	0,25	0,25	0,25	0,88
s4	0,40	0,43	0,35	0,41	0,25	0,25	0,24	0,56
s5	0,25	0,34	0,32	0,30	0,25	0,25	0,25	0,40
s6	0,33	0,30	0,38	0,35	0,25	0,25	0,24	0,52
s7	0,42	0,61	0,56	0,55	0,25	0,25	0,24	0,89
s8	0,52	0,46	0,60	0,58	0,25	0,25	0,25	0,79
s9	0,39	0,56	0,58	0,57	0,25	0,25	0,26	0,81
Média	0,41	0,42	0,47	0,46	0,25	0,25	0,25	0,69

Fonte – Wallace Almeida, 2021

Considerando os resultados para a variação 2, descritos nas tabelas 11, 12 e 13, pode-se dizer que, de modo geral, houve uma pequena redução no desempenho médio de uma mesma técnica, quando comparado ao resultados da variação 1, para os três classificadores. A performance alcançada pelas características extraídas via CSP mantiveram os melhores resultados. Dessa forma, é possível afirmar que, para as características e algoritmos estudados, o aumento da janela de tempo para treinamento e teste apresentou leve influência negativa na performance dos classificadores para esses indivíduos. Ou seja, delimitar a janela de interesse apresentou uma contribuição para a tarefa de classificação.

Tabela 9 – Resultados utilizando o classificador MLP - abordagem #2 - variação 1

Indivíduo	Higuchi	Katz	RMS	IAV	DWT	EMD	Lyapunov	CSP
s1	0,52	0,46	0,60	0,58	0,26	0,28	0,26	0,85
s2	0,33	0,28	0,29	0,29	0,26	0,23	0,28	0,55
s3	0,63	0,59	0,72	0,70	0,26	0,27	0,25	0,88
s4	0,36	0,45	0,45	0,43	0,26	0,26	0,24	0,64
s5	0,28	0,33	0,25	0,34	0,25	0,26	0,20	0,55
s6	0,38	0,32	0,39	0,42	0,30	0,28	0,24	0,55
s7	0,37	0,61	0,58	0,55	0,26	0,27	0,28	0,90
s8	0,52	0,45	0,58	0,51	0,28	0,23	0,25	0,88
s9	0,50	0,62	0,62	0,70	0,23	0,25	0,24	0,82
Média	0,43	0,46	0,50	0,50	0,26	0,26	0,25	0,74

Fonte – Wallace Almeida, 2021

Tabela 10 – Resultados utilizando o classificador OPF - abordagem #2 - variação 1

Indivíduo	Higuchi	Katz	RMS	IAV	DWT	EMD	Lyapunov	CSP
s1	0,40	0,35	0,40	0,44	0,27	0,25	0,24	0,77
s2	0,25	0,25	0,25	0,26	0,22	0,30	0,26	0,53
s3	0,39	0,39	0,49	0,51	0,26	0,25	0,26	0,83
s4	0,31	0,25	0,34	0,32	0,27	0,26	0,24	0,50
s5	0,26	0,27	0,33	0,27	0,27	0,28	0,27	0,44
s6	0,32	0,30	0,29	0,29	0,27	0,28	0,23	0,52
s7	0,29	0,45	0,40	0,40	0,24	0,21	0,26	0,81
s8	0,30	0,34	0,41	0,37	0,29	0,25	0,23	0,82
s9	0,38	0,53	0,45	0,47	0,30	0,28	0,26	0,76
Média	0,32	0,35	0,37	0,37	0,27	0,26	0,25	0,66

Fonte – Wallace Almeida, 2021

Tabela 11 – Resultados utilizando o classificador SVM - abordagem #2 - variação 2

Indivíduo	Higuchi	Katz	RMS	IAV	DWT	EMD	Lyapunov	CSP
s1	0,50	0,32	0,52	0,52	0,25	0,25	0,28	0,79
s2	0,31	0,27	0,24	0,25	0,25	0,25	0,23	0,54
s3	0,54	0,50	0,61	0,60	0,25	0,25	0,26	0,82
s4	0,40	0,48	0,47	0,45	0,25	0,25	0,26	0,56
s5	0,29	0,33	0,26	0,28	0,25	0,25	0,29	0,46
s6	0,29	0,33	0,39	0,35	0,25	0,25	0,26	0,56
s7	0,39	0,61	0,54	0,55	0,25	0,25	0,26	0,72
s8	0,44	0,41	0,51	0,51	0,25	0,25	0,25	0,65
s9	0,32	0,48	0,50	0,49	0,25	0,25	0,26	0,77
Média	0,39	0,41	0,45	0,44	0,25	0,25	0,26	0,65

Fonte – Wallace Almeida, 2021

Tabela 12 – Resultados utilizando o classificador MLP - abordagem #2 - variação 2

Indivíduo	Higuchi	Katz	RMS	IAV	DWT	EMD	Lyapunov	CSP
s1	0,56	0,51	0,55	0,58	0,25	0,25	0,29	0,79
s2	0,32	0,26	0,30	0,25	0,26	0,26	0,26	0,61
s3	0,60	0,60	0,71	0,69	0,25	0,25	0,27	0,89
s4	0,39	0,43	0,43	0,45	0,23	0,23	0,23	0,60
s5	0,31	0,35	0,32	0,34	0,33	0,33	0,25	0,45
s6	0,33	0,34	0,36	0,39	0,27	0,27	0,26	0,50
s7	0,40	0,59	0,59	0,55	0,25	0,25	0,26	0,73
s8	0,43	0,45	0,53	0,54	0,21	0,21	0,27	0,82
s9	0,46	0,57	0,54	0,57	0,19	0,19	0,26	0,79
Média	0,42	0,46	0,48	0,48	0,25	0,25	0,26	0,69

Fonte – Wallace Almeida, 2021

Tabela 13 – Resultados utilizando o classificador OPF - abordagem #2 - variação 2

Indivíduo	Higuchi	Katz	RMS	IAV	DWT	EMD	Lyapunov	CSP
s1	0,29	0,38	0,39	0,41	0,28	0,25	0,25	0,72
s2	0,25	0,22	0,25	0,26	0,24	0,27	0,21	0,50
s3	0,43	0,36	0,48	0,51	0,23	0,24	0,31	0,73
s4	0,33	0,31	0,35	0,31	0,28	0,29	0,30	0,55
s5	0,25	0,28	0,25	0,27	0,28	0,25	0,24	0,40
s6	0,26	0,28	0,26	0,27	0,31	0,28	0,25	0,48
s7	0,26	0,41	0,32	0,40	0,30	0,24	0,22	0,77
s8	0,34	0,36	0,41	0,38	0,28	0,25	0,24	0,75
s9	0,31	0,47	0,41	0,41	0,28	0,25	0,27	0,73
Média	0,30	0,34	0,35	0,36	0,28	0,26	0,25	0,63

Fonte – Wallace Almeida, 2021

Por fim, as tabelas 14, 15 e 16 apresentam os resultados para a variação 3 da segunda abordagem. De modo geral, todas as características analisadas apresentaram redução na propriedade discriminantes entre as diferentes classes desta tarefa. Um destaque a ser considerado são os CSP. Enquanto nas variações 1 e 2 essa técnica demonstrou performance bastante superior em relação às demais para os três classificadores, nessa variação a queda foi expressiva, apesar de manter a maior acurácia média. Assim, pode-se dizer que mesmo uma característica com desempenho elevado, sem a escolha adequada das faixas de frequência do sinal e da janela da aplicação da técnica, pode ter a acurácia bastante comprometida. O SVM e o OPF foram ainda mais sensíveis a essa queda, comparados à MLP.

Em relação a CNN, o modelo CNN4 obteve, nas três abordagens, os melhores desempenhos médios de acurácia dentre os modelos implementados, como é possível observar nas tabelas 17, 18 e 19. Diferente do que ocorreu com os CSP para as técnicas tradicionais,

Tabela 14 – Resultados utilizando o classificador SVM - abordagem #2 - variação 3

Indivíduo	Higuchi	Katz	RMS	IAV	DWT	EMD	Lyapunov	CSP
s1	0,49	0,26	0,37	0,30	0,25	0,25	0,24	0,31
s2	0,23	0,23	0,31	0,25	0,25	0,25	0,20	0,41
s3	0,52	0,23	0,35	0,31	0,25	0,25	0,28	0,47
s4	0,38	0,28	0,40	0,38	0,25	0,25	0,24	0,40
s5	0,26	0,24	0,28	0,32	0,25	0,25	0,25	0,33
s6	0,32	0,35	0,28	0,27	0,25	0,25	0,25	0,34
s7	0,33	0,35	0,42	0,34	0,25	0,25	0,25	0,67
s8	0,40	0,34	0,38	0,36	0,25	0,25	0,25	0,58
s9	0,47	0,27	0,33	0,38	0,25	0,25	0,25	0,58
Média	0,38	0,28	0,35	0,32	0,25	0,25	0,25	0,45

Fonte – Wallace Almeida, 2021

Tabela 15 – Resultados utilizando o classificador MLP - abordagem #2 - variação 3

Indivíduo	Higuchi	Katz	RMS	IAV	DWT	EMD	Lyapunov	CSP
s1	0,57	0,39	0,35	0,32	0,26	0,25	0,25	0,47
s2	0,26	0,27	0,27	0,26	0,24	0,25	0,26	0,48
s3	0,59	0,30	0,57	0,56	0,26	0,26	0,23	0,65
s4	0,39	0,29	0,32	0,30	0,25	0,25	0,29	0,42
s5	0,23	0,27	0,26	0,26	0,24	0,23	0,28	0,41
s6	0,38	0,34	0,40	0,37	0,26	0,26	0,23	0,36
s7	0,33	0,49	0,44	0,39	0,24	0,25	0,27	0,62
s8	0,59	0,43	0,50	0,53	0,26	0,25	0,24	0,75
s9	0,56	0,44	0,53	0,50	0,26	0,25	0,25	0,72
Média	0,43	0,36	0,40	0,39	0,25	0,25	0,26	0,54

Fonte – Wallace Almeida, 2021

Tabela 16 – Resultados utilizando o classificador OPF - abordagem #2 - variação 3

Indivíduo	Higuchi	Katz	RMS	IAV	DWT	EMD	Lyapunov	CSP
s1	0,39	0,24	0,26	0,29	0,27	0,24	0,23	0,53
s2	0,22	0,23	0,27	0,26	0,26	0,25	0,23	0,46
s3	0,40	0,19	0,30	0,33	0,28	0,28	0,22	0,51
s4	0,31	0,25	0,27	0,29	0,28	0,23	0,23	0,44
s5	0,22	0,31	0,31	0,32	0,23	0,25	0,25	0,36
s6	0,22	0,26	0,28	0,29	0,30	0,27	0,25	0,31
s7	0,28	0,30	0,33	0,28	0,34	0,26	0,30	0,60
s8	0,36	0,26	0,39	0,35	0,30	0,25	0,26	0,68
s9	0,38	0,32	0,43	0,38	0,25	0,23	0,26	0,64
Média	0,31	0,26	0,32	0,31	0,28	0,25	0,25	0,50

Fonte – Wallace Almeida, 2021

os modelos de CNN acompanharam a tendência de queda de performance das demais características, apresentando um desempenho inferior quando comparamos a primeira e a segunda abordagem, exceção feita ao modelo CNN2. Ou seja, aumentar o conjunto de dados de treinamento, produzindo novas instâncias que continham separadamente as quatro divisões dos ritmos de frequência das faixas mu e beta, em geral, não proporcionou aumento da acurácia média.

Dentre as abordagens implementadas, a terceira proporcionou aos quatro modelos alcançarem suas melhores performances, o que indica que a utilização de *crops* resultou em um ganho de desempenho comparado às outras duas abordagens. Nesse cenário, foi possível alcançar um resultado para a CNN4 superior ao obtido para todas as características estudadas, sendo inferior apenas aos resultados do CSP. Podemos afirmar, portanto, que esse conjunto de treinamento consideravelmente maior influenciou na melhora da acurácia das CNNs.

Tabela 17 – Resultados utilizando CNNs com 4 faixas - abordagem 1

Indivíduo	CNN1	CNN2	CNN3	CNN4
s1	0,42	0,56	0,57	0,60
s2	0,30	0,26	0,34	0,34
s3	0,38	0,41	0,51	0,53
s4	0,30	0,35	0,33	0,39
s5	0,28	0,25	0,24	0,26
s6	0,27	0,29	0,30	0,31
s7	0,30	0,42	0,47	0,45
s8	0,34	0,40	0,42	0,44
s9	0,47	0,56	0,64	0,62
Média	0,34	0,39	0,43	0,44

Fonte – Wallace Almeida, 2021

Tabela 18 – Resultados utilizando CNNs - abordagem 2

Indivíduo	CNN1	CNN2	CNN3	CNN4
s1	0,39	0,27	0,53	0,42
s2	0,28	0,30	0,32	0,39
s3	0,32	0,26	0,50	0,75
s4	0,37	0,28	0,33	0,34
s5	0,31	0,25	0,25	0,64
s6	0,28	0,28	0,30	0,42
s7	0,27	0,25	0,29	0,59
s8	0,31	0,28	0,46	0,62
s9	0,35	0,35	0,57	0,69
Média	0,32	0,28	0,39	0,54

Fonte – Wallace Almeida, 2021

Tabela 19 – Resultados utilizando CNNs com *crops* - abordagem 3

Indivíduo	CNN1	CNN2	CNN3	CNN4
s1	0,43	0,59	0,64	0,75
s2	0,31	0,33	0,36	0,44
s3	0,33	0,40	0,52	0,78
s4	0,56	0,54	0,39	0,53
s5	0,31	0,24	0,48	0,61
s6	0,29	0,29	0,31	0,43
s7	0,28	0,46	0,53	0,61
s8	0,32	0,39	0,48	0,64
s9	0,37	0,37	0,66	0,73
Média	0,36	0,40	0,49	0,61

Fonte – Wallace Almeida, 2021

Nessa terceira abordagem, no entanto, foi possível observar a ocorrência de sobreajuste no decorrer de poucas épocas da etapa de treinamento. É provável que esse comportamento seja influenciado pela alta correlação desses dados, uma vez que entre dois *crops* subsequentes há uma variação pequena, que consiste de apenas uma amostra dentre as 500 presentes em cada *crop*.

Considerando os resultados de todos os experimentos apresentados anteriormente, a figura 29 apresenta uma visão consolidada das melhores performances alcançadas pelos classificadores para cada um dos indivíduos que compõem o conjunto de dados.



Figura 29 – Melhores resultados: indivíduo x classificador

Fonte – Wallace Almeida, 2021

A partir da observação desse consolidado, é possível identificar que os melhores resultados foram obtidos para a rede MLP e o SVM, os quais apresentaram valores muito

próximos entre si para todos os indivíduos. O classificador OPF, apesar de oferecer uma etapa de treinamento muito rápida, apresentou desempenho um pouco inferior, com uma queda ainda mais acentuada nos indivíduos cuja correta classificação apresentou maior grau de dificuldade, como os indivíduos s2 e s6. Vale destacar que a MLP chegou a atingir uma acurácia de 90% para o indivíduo s7, a maior dentre todos os valores observados de acurácia para os classificadores. Comparado aos demais classificadores, as CNNs não apresentaram performance superior considerando seus melhores resultados. Os resultados alcançados mais expressivos foram para os indivíduos s1 e s3, com uma taxa de classificação igual a 75% e 78%, respectivamente. No entanto, para os indivíduos de maior dificuldade destacados anteriormente, as CNNs obtiveram performances inferiores a 50%.

Considerando as técnicas tradicionais, na figura 30 são apresentados os melhores resultados obtidos pelas técnicas de extração de características comparativamente para cada um dos indivíduos estudados.

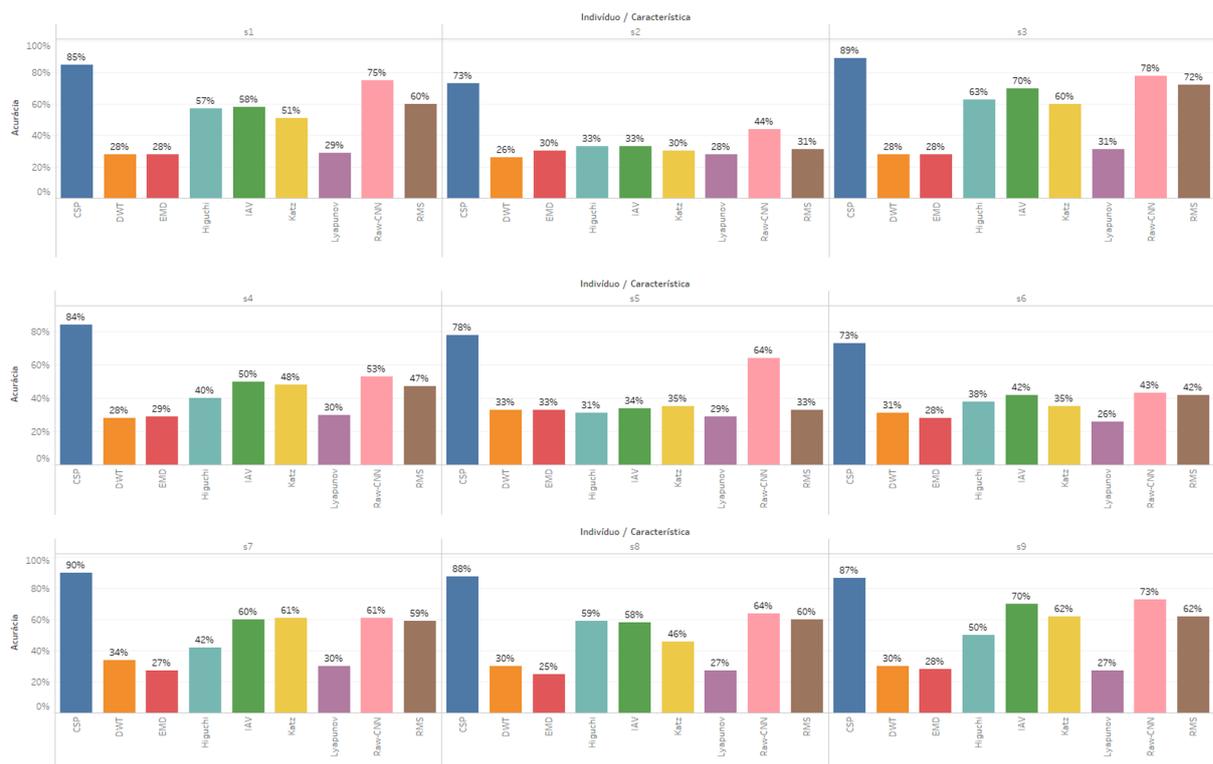


Figura 30 – Melhores resultados: indivíduo x característica

Fonte – Wallace Almeida, 2021

Conforme destacado anteriormente, é possível observar que dentre todos os extratores de características estudados, os CSP apresentaram as melhores performances

para todos os indivíduos, porém apresentaram queda de performance para os indivíduos 2 e 6, comportamento similar ao que ocorreu com as outras técnicas. Uma observação interessante é que as características obtidas automaticamente no processo de treinamento das CNNs, a partir dos dados brutos, mostraram um desempenho relevante, uma vez que seus melhores resultados são ligeiramente menor que aqueles obtidos pelo CSP.

A fim de detalhar como a performance obtida pelos algoritmos está distribuída dentre as tarefas do problema de classificação de MI, foram construídas duas matrizes de confusão, uma para um representante das técnicas tradicionais e uma para as CNNs. A tabela 20 apresenta a matriz de confusão para a MLP utilizando CSP como extrator de característica na abordagem #1, e a tabela 21 para a CNN4 da terceira abordagem. Como é possível observar, em ambos os algoritmos, o MI relacionado ao movimentos dos pés apresenta maior complexidade para correta classificação. Dentre as quatro tarefas estudadas, esse movimento, quando classificado de maneira incorreta, é identificado mais frequentemente como um movimento da língua. Os movimentos das mãos, apesar das ativações ocorrerem em hemisférios separados do cérebro, são movimentos mais relacionados entre si, quando comparado aos outros dois.

Tabela 20 – Matriz de confusão para os melhores resultados MLP

		Previsto			
		Mão esquerda	Mão direita	Pés	Língua
Real	Mão esquerda	83,49% (541)	8,33% (54)	4,78% (31)	3,40% (22)
	Mão direita	10,34% (67)	80,86% (524)	5,25% (34)	3,55% (23)
	Pés	8,18% (53)	6,02% (39)	75,93% (492)	9,87% (64)
	Língua	6,79% (44)	7,71% (50)	7,10% (46)	78,40% (508)

Fonte – Wallace Almeida, 2021

Tabela 21 – Matriz de confusão para os melhores resultados CNN

		Previsto			
		Mão esquerda	Mão direita	Pés	Língua
Real	Mão esquerda	66,08% (267k)	16,26% (66k)	9,44% (38k)	8,22% (33k)
	Mão direita	15,56% (63k)	66,38% (269k)	9,25% (37k)	8,81% (36k)
	Pés	13,67% (55k)	15,54% (63k)	54,37% (220k)	16,42% (66k)
	Língua	13,14% (53k)	16,83% (68k)	11,73% (47k)	58,30% (236k)

Fonte – Wallace Almeida, 2021

A comparação da acurácia média obtida nos experimentos deste trabalho com outros modelos da literatura, que empregaram o mesmo conjunto de dados, é mostrada na tabela 22. A abordagem que utiliza CSP como extrator de características e SVM como

classificador apresentou performance superior aos trabalhos de [Khan et al. \(2020\)](#) e [Ai et al. \(2019\)](#), para a mesma técnica e algoritmo de classificação, com um valor de acurácia de 0,82 contra 0,75 e 0,73, respectivamente. Em ambos os trabalhos comparados não há descrição dos parâmetros de configuração do algoritmo SVM, e o refinamento destes apresentou influência positiva nos resultados.

Em [Ai et al. \(2019\)](#) é utilizada uma técnica de extração de característica denominada decomposição em escala característica local (do inglês *Local Characteristic-scale Decomposition* - LCD) ([JUNSHENG; JINDE; YANG, 2012](#)), descrita como sendo comparável à técnica EMD. Do mesmo modo que o observado com a EMD, que apresentou acurácia média de 0,26, a técnica LCD não foi capaz de gerar características com alto poder discriminante para a tarefa de MI, proporcionando uma acurácia média de 0,28.

Com relação às CNNs, a performance obtida nos experimentos não superou o resultado destacado em [Amin et al. \(2019\)](#). A melhor acurácia neste trabalho atingiu o valor de 0,61 contra o valor observado de 0,76. Vale destacar que as configurações apresentadas no trabalho comparado utilizam redes pré-treinadas em outros conjuntos de dados, além de empregarem fusão de características, ao combinar características obtidas com diferentes arquiteturas de CNN para a etapa de classificação.

Tabela 22 – Comparação de resultados para o conjunto de dados BCI IV - 2a

Estudo	Abordagem	Acurácia Média
Khan et al. (2020)	CSP + SVM	0,75
Ai et al. (2019)	CSP + SVM	0,73
Este trabalho	CSP + SVM	0,82
Ai et al. (2019)	LCD + SVM	0,28
Este trabalho	EMD + SVM	0,26
Amin et al. (2019)	CNN	0,76
Este trabalho	CNN	0,61

Fonte – Wallace Almeida, 2021

6 Conclusão e trabalhos futuros

A proposta deste trabalho foi investigar a performance de três técnicas tradicionais de aprendizado de máquina (SVM, MLP e OPF), para a realização da tarefa de classificação de MI (movimento da mão esquerda, mão direita, pés e língua) em interfaces cérebro-computador baseadas em sinais de EEG. Essa comparação foi realizada utilizando diferentes tipos de extratores de características, como dimensão fractal, características estatísticas, CSP, DWT, EMD, e expoentes de Lyapunov, em duas abordagens distintas. A influência da seleção da janela e o impacto da delimitação da faixa de frequência de interesse também foram analisadas, além dos efeitos proporcionados na combinação de características dessas faixas. Adicionalmente, foram conduzidos experimentos com um conjunto de modelos de CNN, representante das técnicas de aprendizado profundo, a fim de comparar o desempenho em mais três propostas de abordagens.

Para a condução deste estudo, foi selecionado o conjunto de dados 2a da Competição IV de BCI de 2008, presente em diversos estudos na literatura, o que permite relacionar de maneira direta, os resultados aqui obtidos com o encontrado em outros trabalhos.

A respeito das abordagens propostas para as técnicas tradicionais, enquanto a primeira combina características extraídas a partir de diferentes faixas de frequência, que compõem os ritmos mu e beta, a segunda abordagem propõe avaliar a influência da restrição da faixa de frequência aos ritmos de interesse e da seleção de uma janela menor do sinal na performance alcançada, por meio de três variações.

O extrator de características CSP produziu o melhor desempenho observado nos classificadores. Em contrapartida, as técnicas DWT, EMD e Lyapunov, aplicadas com sucesso em outros contextos, não puderam ser consideradas como características com alto poder discriminante para as tarefas de MI, objeto deste estudo.

Dentre as diferentes configurações, os melhores resultados para o CSP foram obtidos para o classificador MLP, adotando a estrutura de banco de filtros descrita na abordagem #1, superando o resultados apresentados em [Khan *et al.* \(2020\)](#). Vale destacar também que os demais extratores não proporcionaram esse mesmo ganho de performance nos classificadores, em comparação com os melhores resultados da abordagem #2.

De um modo geral, para os três classificadores, pode-se afirmar que para as técnicas de extração de características aqui empregadas, a escolha de uma janela reduzida para

aplicação das técnicas apresentaram pouca interferência na performance do classificador quando comparados ao período de interesse para intenção de movimento.

A partir desses resultados, também é possível afirmar que a análise do sinal não direcionada para faixas de frequências mais relevantes para imagética motora, acarreta em queda no desempenho dos classificadores, conforme hipóteses levantadas.

Sob a ótica das técnicas de CNNs, a utilização dos *crops* obtidos a partir de uma janela deslizante sobre o sinal como entradas para arquitetura especificada para a CNN4 produziu os melhores resultados para essas abordagens, ficando mais próximo do melhor desempenho para as técnicas tradicionais neste conjunto de dados.

Além das análises comparativas apresentadas neste estudo, relacionadas aos extratores e classificadores escolhidos, influência da janela do sinal e faixas de frequência, existem ainda possibilidades a serem exploradas. Como trabalhos futuros pretende-se investigar outras técnicas de extração de característica, como por exemplo o método auto-regressivo adaptativo (*adaptive auto-regressive* - AAR) e expoente de Hurst (*Hurst Exponent* - HE), a fim de potencialmente obter um desempenho comparado ao melhores resultados já obtidos.

A influência da aplicação de técnicas de seleção das características para encontrar um subconjunto mais relevantes dentre todas as geradas pelos extratores é um aspecto que apresenta oportunidade de estudo. Estratégias para identificar e selecionar os canais mais relevantes para a tarefa de MI também poderiam ser aplicadas a fim de buscar redução de custo computacional e melhora na performance.

Os experimentos foram direcionados especificadamente para cada indivíduo. Como expansão de escopo poderia ser aplicados métodos de aprendizado por transferência (*transfer learning*), de modo a avaliar a viabilidade e identificar potencial de generalização, realizando a etapa de treinamento sobre um conjunto de indivíduos diferente do conjunto de indivíduo de teste.

Para o cenário de aprendizado profundo, é possível buscar estratégias que utilizam redes pré-treinadas em outros conjuntos de dados, possivelmente com mais amostras, a fim de reduzir ainda mais os efeitos de sobre-ajuste. Adicionalmente, existe a possibilidade de explorar mais detalhadamente a combinação das características obtidas por diferentes modelos.

Por fim, extensões deste trabalho poderiam aplicar as técnicas que apresentaram melhores resultados para a tarefa de MI em BCIs baseadas em EEG para outros tipos de sinais biomédicos, tais como eletromiograma e eletrocardiograma.

Referências

- AI, Q.; CHEN, A.; CHEN, K.; LIU, Q.; ZHOU, T.; XIN, S.; JI, Z. Feature extraction of four-class motor imagery eeg signals based on functional brain network. *Journal of Neural Engineering*, v. 16, 01 2019. Citado na página 73.
- ALMEIDA, W. F.; LIMA, C. A. M.; PERES, S. M. A systematic mapping of feature extraction and feature selection methods of electroencephalogram signals for neurological diseases diagnostic. *IEEE Latin America Transactions*, v. 19, p. 735–745, 05 2021. Citado 3 vezes nas páginas 15, 31 e 84.
- AMIN, S.; ALSULAIMAN, M.; MUHAMMAD, G.; AMINE, M.; HOSSAIN, M. S. Deep learning for eeg motor imagery classification based on multi-layer cnns feature fusion. *Future Generation Computer Systems*, v. 101, 07 2019. Citado 2 vezes nas páginas 61 e 73.
- ANDRADE, M. K.; SANTANA, M. A. de; MORENO, G.; OLIVEIRA, I.; SANTOS, J.; RODRIGUES, M. C. A.; SANTOS, W. P. d. An eeg brain-computer interface to classify motor imagery signals. In: NAIK, G. (Ed.). *Biomedical Signal Processing: Advances in Theory, Algorithms and Applications*. Singapore: Springer Singapore, 2020. p. 83–98. ISBN 978-981-13-9097-5. Citado na página 30.
- AZLAN, W. W.; LOW, Y. Feature extraction of electroencephalogram (eeg) signal - a review. In: . [S.l.: s.n.], 2015. p. 801–806. Citado na página 16.
- BASHASHATI, A.; FATOURECHI, M.; WARD, R.; BIRCH, G. A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals. *Journal of neural engineering*, v. 4, p. R32–57, 07 2007. Citado na página 26.
- BASTOS-FILHO, T. F. In: *Introduction to Non-Invasive EEG-Based Brain-Computer Interfaces for Assistive Technologies*. [S.l.]: CRC Press, 2020. p. 84. ISBN 9781000090727. Citado na página 21.
- BERGER, H. Über das elektrenkephalogramm des menschen. *Archiv f. Psychiatrie*, v. 87, p. 527–570, 12 1929. Citado na página 20.
- BLINOWSKA, K.; DURKA, P. Electroencephalography (eeg). In: *Wiley Encyclopedia of Biomedical Engineering*. [S.l.]: American Cancer Society, 2006. ISBN 9780471740360. Citado na página 21.
- BOOSTANI, R.; KARIMZADEH, F.; NAMI, M. A comparative review on sleep stage classification methods in patients and healthy individuals. *Computer Methods and Programs in Biomedicine*, v. 140, p. 77–91, 2017. Citado 3 vezes nas páginas 16, 31 e 32.
- BOUBCHIR, L.; DAACHI, B.; PANGRACIOUS, V. A review of feature extraction for eeg epileptic seizure detection and classification. In: . [S.l.: s.n.], 2017. v. 2017-January, p. 456–460. Citado 2 vezes nas páginas 16 e 31.
- CHAUDHARY, S.; TARAN, S.; BAJAJ, V.; SENGUR, A. Convolutional neural network based approach towards motor imagery tasks eeg signals classification. *IEEE Sensors Journal*, PP, p. 1–1, 02 2019. Citado 3 vezes nas páginas 51, 54 e 55.

- CORTES, C.; VAPNIK, V. Support-vector networks. *Mach. Learn.*, Kluwer Academic Publishers, Hingham, MA, USA, v. 20, n. 3, p. 273–297, set. 1995. ISSN 0885-6125. Citado 2 vezes nas páginas 44 e 47.
- CRAIK, A.; HE, Y.; CONTRERAS-VIDAL, J. Deep learning for electroencephalogram (eeg) classification tasks: A review. *Journal of Neural Engineering*, v. 16, 02 2019. Citado 2 vezes nas páginas 51 e 53.
- DIYKH, M.; LI, Y. Complex networks approach for eeg signal sleep stages classification. *Expert Systems with Applications*, v. 63, p. 241–248, 2016. Citado na página 16.
- FU, M.; DALY, J.; CAVUSOGLU, M. Assessment of eeg event-related desynchronization in stroke survivors performing shoulder-elbow movements. In: . [S.l.: s.n.], 2006. p. 3158 – 3164. Citado na página 22.
- GÜLER, N. F.; ÜBEYLI, E. D.; GÜLER İnan. Recurrent neural networks employing lyapunov exponents for eeg signals classification. *Expert Systems with Applications*, v. 29, n. 3, p. 506 – 514, 2005. ISSN 0957-4174. Citado na página 39.
- HA, K.-W.; JEONG, J.-W. Motor imagery eeg classification using capsule networks. *Sensors*, v. 19, p. 2854, 06 2019. Citado 2 vezes nas páginas 16 e 55.
- HANAKAWA, T.; DIMYAN, M.; HALLETT, M. Motor planning, imagery, and execution in the distributed motor network: a time-course study with functional mri. *Cerebral cortex*, v. 18 12, p. 2775–88, 2008. Citado na página 29.
- HARPALE, V.; BAIRAGI, V. Time and frequency domain analysis of eeg signals for seizure detection: A review. In: . [S.l.: s.n.], 2016. Citado na página 31.
- HAYKIN, S. *Redes neurais: princípios e prática*. [S.l.]: Bookman Editora, 2001. Citado 3 vezes nas páginas 40, 41 e 42.
- HE, H.; WU, D. Transfer learning for brain-computer interfaces: A euclidean space data alignment approach. *IEEE Transactions on Biomedical Engineering*, PP, p. 1–1, 04 2019. Citado na página 25.
- HIGUCHI, T. Approach to an irregular time series on the basis of the fractal theory. *Physica D: Nonlinear Phenomena*, v. 31, n. 2, p. 277 – 283, 1988. ISSN 0167-2789. Citado na página 35.
- HOSSEINI, M.-P.; HAJISAMI, A.; POMPILI, D. Real-time epileptic seizure detection from eeg signals via random subspace ensemble learning. In: . [S.l.: s.n.], 2016. p. 209–218. Citado na página 23.
- HUANG, N.; SHEN, Z.; LONG, S.; WU, M.; SHIH, H.; ZHENG, Q.; YEN, N.; TUNG, C.; LIU, H. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *PROCEEDINGS OF THE ROYAL SOCIETY A-MATHEMATICAL PHYSICAL AND ENGINEERING SCIENCES*, 454, n. 1971, p. 903–995, MAR 8 1998. ISSN 1364-5021. Citado 2 vezes nas páginas 37 e 38.
- HUSSEIN, R.; MOHAMED, A.; SHAHAN, K.; MOHAMED, A. Eeg feature extraction and selection techniques for epileptic detection: A comparative study. In: . [S.l.: s.n.], 2013. p. 170–175. Citado na página 16.

- JAISSWAL, A.; BANKA, H. Epileptic seizure detection in eeg signal using machine learning techniques. *Australasian Physical and Engineering Sciences in Medicine*, v. 41, n. 1, p. 81–94, 2018. Citado na página 24.
- JENKE, R.; PEER, A.; BUSS, M. Feature extraction and selection for emotion recognition from eeg. *IEEE Transactions on Affective Computing*, v. 5, n. 3, p. 327–339, 2014. Citado 2 vezes nas páginas 31 e 32.
- JIANG, D.; LU, Y.-N.; MA, Y.; WANG, Y. Robust sleep stage classification with single-channel eeg signals using multimodal decomposition and hmm-based refinement. *Expert Systems with Applications*, v. 121, p. 188–203, 2019. Citado na página 24.
- JUNSHENG, C.; JINDE, Z.; YANG, Y. A nonstationary signal analysis approach - the local characteristic-scale decomposition method. *Zhendong Gongcheng Xuebao/Journal of Vibration Engineering*, v. 25, p. 215–220, 04 2012. Citado na página 73.
- KATZ, M. J. Fractals and the analysis of waveforms. *Computers in Biology and Medicine*, v. 18, n. 3, p. 145 – 156, 1988. ISSN 0010-4825. Citado na página 34.
- KHAMPARIA, A.; SINGH, K. A systematic review on deep learning architectures and applications. *Expert Systems*, v. 36, p. e12400, 03 2019. Citado 2 vezes nas páginas 51 e 55.
- KHAN, G.; HASHMI, M.; AWAIS, M.; KHAN, N.; BASIR, R. High performance multi-class motor imagery eeg classification. In: . [S.l.: s.n.], 2020. p. 149–155. Citado 4 vezes nas páginas 32, 57, 73 e 74.
- KITCHENHAM, B.; CHARTERS, S. *Guidelines for performing Systematic Literature Reviews in Software Engineering*. [S.l.], 2007. Disponível em: <http://www.dur.ac.uk/ebse/resources/Systematic-reviews-5-8.pdf>. Citado na página 82.
- KLEM, G. H.; LÜDERS, H. O.; JASPER, H. H.; ELGER, C. The ten-twenty electrode system of the international federation. the international federation of clinical neurophysiology. *Electroencephalography and clinical neurophysiology. Supplement*, v. 52, p. 3–6, 1958. Citado na página 22.
- KOCADAGLI, O.; LANGARI, R. Classification of eeg signals for epileptic seizures using hybrid artificial neural networks based wavelet transforms and fuzzy relations. *Expert Systems with Applications*, v. 88, p. 419–434, 2017. Citado na página 36.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. Imagenet classification with deep convolutional neural networks. *Neural Information Processing Systems*, v. 25, 01 2012. Citado na página 61.
- LANFER, B.; SCHERG, M.; DANNHAUER, M.; KNÖSCHE, T.; BURGER, M.; WOLTERS, C. Influences of skull segmentation inaccuracies on eeg source analysis. *NeuroImage*, v. 62, p. 418–31, 05 2012. Citado na página 23.
- LI, S.; ZHOU, W.; YUAN, Q.; GENG, S.; CAI, D. Feature extraction and recognition of ictal eeg using emd and svm. *Computers in Biology and Medicine*, v. 43, n. 7, p. 807–816, 2013. Citado na página 38.

- LI, Y.; CUI, W.; LUO, M.; LI, K.; WANG, L. Epileptic seizure detection based on time-frequency images of eeg signals using gaussian mixture model and gray level co-occurrence matrix features. *International Journal of Neural Systems*, v. 28, n. 7, 2018. Citado na página 16.
- LI, Y.; HU, B.; ZHENG, X.; LI, X. Eeg-based mild depressive detection using differential evolution. *IEEE Access*, 2018. Citado na página 23.
- LIMA, C. A. de M. *Comitê de máquinas: uma abordagem unificada empregando máquinas de vetores-suporte*. Tese (Doutorado) — Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação, Campinas, SP, 2004. Citado 2 vezes nas páginas 46 e 47.
- LOTTE, F.; BOUGRAIN, L.; CICHOCKI, A.; CLERC, M.; CONGEDO, M.; RAKOTOMAMONJY, A.; YGER, F. A review of classification algorithms for eeg-based brain-computer interfaces: A 10 year update. *Journal of Neural Engineering*, v. 15, n. 3, 2018. Citado 2 vezes nas páginas 15 e 26.
- LOTZE, M.; MONTOYA, P.; ERB, M.; HÜLSMANN, E.; FLOR, H.; KLOSE, U.; BIRBAUMER, N.; GRODD, W. Activation of cortical and cerebellar motor areas during executed and imagined hand movements: an fmri study. *Journal of cognitive neuroscience*, v. 11, n. 5, p. 491—501, September 1999. ISSN 0898-929X. Citado na página 23.
- LU, Y.; MA, Y.; CHEN, C.; WANG, Y. Classification of single-channel eeg signals for epileptic seizures detection based on hybrid features. *Technology and Health Care*, v. 26, n. S1, p. S337–S346, 2018. Citado na página 38.
- LÓPEZ-LARRAZ, E.; SANZ, A. S.; LANDA, N. I.; BIRBAUMER, N.; RAMOS-MURGUIALDAY, A. Brain-machine interfaces for rehabilitation in stroke: A review. *Neurorehabilitation*, v. 43, p. 77–97, 08 2018. Citado na página 25.
- MINGUILLON, J.; LOPEZ-GORDO, M. A.; PELAYO, F. Trends in eeg-bci for daily-life: Requirements for artifact removal. *Biomedical Signal Processing and Control*, v. 31, p. 407–418, 2017. ISSN 1746-8094. Citado na página 24.
- NICOLAS-ALONSO, L.; GOMEZ-GIL, J. Brain computer interfaces, a review. *Sensors*, v. 12, n. 2, p. 1211–1279, 2012. Citado 3 vezes nas páginas 27, 28 e 29.
- NUNES, T.; COELHO, A.; LIMA, C.; PAPA, J.; ALBUQUERQUE, V. D. Eeg signal classification for epilepsy diagnosis via optimum path forest - a systematic assessment. *Neurocomputing*, v. 136, p. 103–123, 2014. Citado na página 48.
- NUNEZ, P. L.; SRINIVASAN, R.; WESTDORP, A. F.; WIJESINGHE, R. S.; TUCKER, D. M.; SILBERSTEIN, R. B.; CADUSCH, P. J. Eeg coherency: I: statistics, reference electrode, volume conduction, laplacians, cortical imaging, and interpretation at multiple scales. *Electroencephalography and Clinical Neurophysiology*, v. 103, n. 5, p. 499–515, 1997. ISSN 0013-4694. Citado na página 23.
- PADFIELD, N.; ZABALZA, J.; ZHAO, H.; VARGAS, V.; REN, J. Eeg-based brain-computer interfaces using motor-imagery: techniques and challenges. *Sensors*, MDPI AG, v. 19, n. 6, mar. 2019. ISSN 1424-8220. Citado 2 vezes nas páginas 28 e 29.

- PAPA, J.; FALCÃO, A.; SUZUKI, C. Supervised pattern classification based on optimum-path forest. *International Journal of Imaging Systems and Technology*, v. 19, n. 2, p. 120–131, 2009. Citado 2 vezes nas páginas 47 e 48.
- PARVEZ, M.; PAUL, M. Novel approaches of eeg signal classification using imf bandwidth and dct frequency. *Biomedical Engineering - Applications, Basis and Communications*, v. 27, n. 3, 2015. Citado na página 20.
- PFURTSCHELLER, G.; NEUPER, C. Neuper, c.: Motor imagery and direct brain-computer communication. *proc. ieee* 82(7), 1123-1134. *Proceedings of the IEEE*, v. 89, p. 1123 – 1134, 08 2001. Citado na página 28.
- PHINYOMARK, A.; LIMSAKUL, C.; PHUKPATTARANONT, P. A novel feature extraction for robust EMG pattern recognition. *CoRR*, abs/0912.3973, 2009. Citado na página 56.
- RAGHAVENDRA, B.; Narayana Dutt, D. A note on fractal dimensions of biomedical waveforms. *Computers in Biology and Medicine*, v. 39, n. 11, p. 1006 – 1012, 2009. ISSN 0010-4825. Citado na página 34.
- RAGHU, S.; SRIRAAM, N. Classification of focal and non-focal eeg signals using neighborhood component analysis and machine learning algorithms. *Expert Systems with Applications*, v. 113, p. 18–32, 2018. Citado na página 44.
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, v. 65 6, p. 386–408, 1958. Citado na página 40.
- ROY, Y.; BANVILLE, H.; ALBUQUERQUE, I.; GRAMFORT, A.; FALK, T. H.; FAUBERT, J. Deep learning-based electroencephalography analysis: a systematic review. *Journal of Neural Engineering*, IOP Publishing, v. 16, n. 5, p. 051001, aug 2019. Citado 3 vezes nas páginas 16, 53 e 55.
- SCHIRMEISTER, R.; SPRINGENBERG, J.; FIEDERER, L.; GLASSTETTER, M.; EGGENSBERGER, K.; TANGERMANN, M.; HUTTER, F.; BURGARD, W.; BALL, T. Deep learning with convolutional neural networks for eeg decoding and visualization: Convolutional neural networks in eeg analysis. *Human Brain Mapping*, v. 38, 08 2017. Citado na página 59.
- SELIM, S.; TANTAWI, M.; SHEDEED, H.; BADR, A. A comparative analysis of different feature extraction techniques for motor imagery based bci system. In: HASSANIEN, A.-E.; AZAR, A. T.; GABER, T.; OLIVA, D.; TOLBA, F. M. (Ed.). *Proceedings of the International Conference on Artificial Intelligence and Computer Vision (AICV2020)*. Cham: Springer International Publishing, 2020. p. 740–749. Citado na página 58.
- SHARMILA, A.; MAHALAKSHMI, P. Wavelet-based feature extraction for classification of epileptic seizure eeg signal. *Journal of Medical Engineering and Technology*, v. 41, n. 8, p. 670–680, 2017. Citado 3 vezes nas páginas 35, 36 e 37.
- SRIVASTAVA, N.; HINTON, G.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, v. 15, n. 56, p. 1929–1958, 2014. Citado na página 53.

- SUN, S.; ZHOU, J. A review of adaptive feature extraction and classification methods for eeg-based brain-computer interfaces. In: . [S.l.: s.n.], 2014. p. 1746–1753. Citado 2 vezes nas páginas 15 e 25.
- TANDLE, A.; JOSHI, M.; DHARMADHIKARI, A.; JAISWAL, S. Mental state and emotion detection from musically stimulated eeg. *Brain Informatics*, v. 5, n. 2, 2018. Citado na página 24.
- TANGERMANN, M.; MÜLLER, K.-R.; AERTSEN, A.; BIRBAUMER, N.; BRAUN, C.; BRUNNER, C.; LEEB, R.; MEHRING, C.; MILLER, K.; MUELLER-PUTZ, G.; NOLTE, G.; PFURTSCHELLER, G.; PREISSEL, H.; SCHALK, G.; SCHLÖGL, A.; VIDAURRE, C.; WALDERT, S.; BLANKERTZ, B. Review of the bci competition iv. *Frontiers in Neuroscience*, v. 6, p. 55, 2012. ISSN 1662-453X. Citado 2 vezes nas páginas 56 e 57.
- THIBODEAU, R.; JORGENSEN, R.; KIM, S. Depression, anxiety, and resting frontal eeg asymmetry: A meta-analytic review. *Journal of abnormal psychology*, v. 115, p. 715–29, 12 2006. Citado na página 24.
- TRAD, D.; AL-ANI, T.; JEMNI, M. A feature extraction technique of eeg based on emd-bp for motor imagery classification in bci. In: . [S.l.: s.n.], 2016. Citado na página 38.
- VAID, S.; SINGH, P.; KAUR, C. Eeg signal analysis for bci interface: A review. In: . [S.l.: s.n.], 2015. v. 2015-April, p. 143–147. Citado 3 vezes nas páginas 20, 21 e 24.
- VIDYARATNE, L.; IFTEKHARUDDIN, K. Real-time epileptic seizure detection using eeg. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 25, n. 11, p. 2146–2156, 2017. Citado na página 20.
- VIEIRA, R. A. de F. *Seleção de canais para reconhecimento biométrico baseado em sinais de eletroencefalograma*. Dissertação (Mestrado) — Escola de Artes, Ciências e Humanidades, Universidade de São Paulo, 2019. Citado na página 25.
- WOLPAW, J. R.; BIRBAUMER, N.; MCFARLAND, D. J.; PFURTSCHELLER, G.; VAUGHAN, T. M. Brain-computer interfaces for communication and control. *Clinical Neurophysiology*, v. 113, n. 6, p. 767–791, 2002. ISSN 1388-2457. Citado na página 26.
- WOLPAW JONATHAN R. AND WOLPAW, E. W. In: *Brain Computer Interfaces, Principles and Practise*. [S.l.]: Oxford University Press, 2012. p. 424. ISBN 978-019538885-5. Citado na página 24.
- YUAN, Q.; ZHOU, W.; XU, F.; LENG, Y.; WEI, D. Epileptic eeg identification via lbp operators on wavelet coefficients. *International Journal of Neural Systems*, v. 28, n. 8, 2018. Citado na página 45.
- ZHAO, D.; WANG, Y.; WANG, Q.; WANG, X. Comparative analysis of different characteristics of automatic sleep stages. *Computer Methods and Programs in Biomedicine*, v. 175, p. 53 – 72, 2019. ISSN 0169-2607. Citado na página 32.

Apêndice A – Protocolo do mapeamento sistemático

Segundo [Kitchenham e Charters \(2007\)](#), o protocolo de um Mapeamento Sistemático (MS) define o método empregado para conduzir o mapeamento. Sua construção, para este MS, compreende: (i) definição dos motores de busca; (ii) estratégia de pesquisa; (iii) estratégia de seleção de estudos primários; (iv) estratégia de avaliação da qualidade dos estudos; e (v) métodos de extração e síntese dos dados.

1. **Definição dos motores de busca:** Os motores de busca utilizados foram *Scopus* e *Web of Science* (WoS). Estes foram escolhidos a fim de maximizar o número de estudos elegíveis recuperados, uma vez que eles contemplam as principais editoras digitais, como *IEEEExplore*, *Elsevier* e *Springer-Link*.
2. **Estratégia de pesquisa:** Para a estratégia de pesquisa, uma string de busca canônica foi elaborada. Sua elaboração visou maximizar o número de estudos elegíveis recuperados para esse MS, contemplando flexões de número (singular e plural), siglas e expressões completas, variações pela presença de hífen e etc. Inicialmente, a *string* busca trabalhos relacionados às etapas de extração ou seleção de características. Em seguida restringe às possíveis variações de EEG ou a área de interface cérebro-computador. Por fim limita a busca por técnicas com objetivo de diagnóstico de algum distúrbio.

Tabela 23 – Representação canônica da string de busca

("Feature* Select*" OR "Feature* Extract*") AND
 ("EEG" OR "Electroencephalogra*" OR
 "Electro-encephalogra*" OR "brain computer interfac*") AND
 ("diagnos*" OR "detect*" OR "recognit*") AND
 ("disease" OR "seizure") AND
 ("technique*" OR "strateg*" OR "method*")

Fonte – Wallace Almeida, 2021

3. **Estratégia de seleção de estudos primários:** A estratégia de seleção de estudos primários ocorreu a partir da definição de um conjunto de critérios de inclusão (CI) e exclusão (CE). Esses critérios foram elaborados de modo a selecionar estudos acessíveis e pertencentes ao escopo do MS. Após a aplicação da *string* nos motores de busca, um estudo recuperado é selecionado como estudo primário se todos os CI

forem satisfeitos. No entanto, se o estudo tiver ao menos um critério de exclusão satisfeito, ele é descartado.

Critérios de Inclusão

- (CI1) Trabalhos que adotem e descrevam uma ou mais técnicas de extração ou seleção de características empregadas na classificação do sinal de EEG, e não apenas mencionem que a atividade constitui uma etapa do processo.
- (CI2) Trabalhos que adotem e descrevam uma ou mais técnicas de extração ou seleção de características empregadas em pesquisas da área de interface cérebro-computador.

Critérios de Exclusão

- (CE1) Trabalhos não disponibilizados eletronicamente na Internet.
- (CE2) Trabalhos não disponíveis no idioma Inglês.
- (CE3) Trabalhos não relacionados diretamente às áreas de Ciência da Computação e Engenharia.
- (CE4) Trabalhos com ano de publicação anterior a 2013.
- (CE5) Trabalhos classificados como estudos secundários, tais como questionários e revisões.
- (CE6) Trabalhos não revisados por pares tais como relatórios técnicos, livros, capítulos de livros, etc.
- (CE7) Trabalhos que abordam as técnicas de extração ou técnicas de seleção de características de maneira pouco precisa, ou então combinadas com outros tipos de sinais.

4. **Estratégia de avaliação da qualidade:** Para avaliação da qualidade dos estudos primários foram estabelecidos critérios de qualidade (CQ) que permitiram analisar e comparar a qualidade e relevância dos estudos selecionados. Para elaborar os critérios de qualidade, foram considerados fatores relacionados à contribuição, detalhamento do trabalho, possibilidade de replicação das técnicas e disponibilização de expressões matemáticas baseadas nos conceitos descritos ou propostos nos estudos.

- (CQ1) O método de experimentação é apresentado?

- (CQ2) As expressões para as técnicas de extração de características são formalmente apresentadas?
- (CQ3) As técnicas de seleção de características são formalmente apresentadas?
- (CQ4) A proposta do artigo é comparada com outras propostas?
- (CQ5) As bases de dados estão disponíveis para fins de reprodutibilidade?

Para cada um dos cinco critérios de qualidades listados, pontuações foram atribuídas da seguinte forma: 1 - se o critério foi satisfeito em sua totalidade; 0,5 - se o critério foi atendido de modo parcial; 0 - se o critério não foi satisfeito

5. **Métodos de extração e síntese dos dados:** Com as devidas pontuações atribuídas aos estudos primários, foi possível identificar aqueles com maior relevância para o estudo das técnicas de extração e seleção de características e assim fundamentar as respostas para as questões de pesquisa de modo sistemático.

O mapeamento completo e os resultados obtidos foram publicados em [Almeida, Lima e Peres \(2021\)](#).