

**UNIVERSIDADE FEDERAL DE ITAJUBÁ - UNIFEI
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA**

Classificação Multiclasse de Sinais de
Eletroencefalograma para Tarefas de
Imaginação Motora utilizando Processamento
Estatístico de Sinais e Deep Learning

William Henrique Pereira Costa

Itajubá, 31 de julho de 2023

**UNIVERSIDADE FEDERAL DE ITAJUBÁ - UNIFEI
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA**

William Henrique Pereira Costa

**Classificação Multiclasse de Sinais de
Eletroencefalograma para Tarefas de
Imaginação Motora utilizando Processamento
Estatístico de Sinais e Deep Learning.**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Elétrica como parte dos requisitos para obtenção do Título de Mestre em Ciências em Engenharia Elétrica.

Área de Concentração: Microeletrônica

Orientador: Prof. Dr. Luiz Eduardo Borges Silva

**31 de julho de 2023
Itajubá**

UNIVERSIDADE FEDERAL DE ITAJUBÁ - UNIFEI
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA

Classificação Multiclasse de Sinais de
Eletroencefalograma para Tarefas de
Imaginação Motora utilizando Processamento
Estatístico de Sinais e Deep Learning

William Henrique Pereira Costa

Dissertação aprovada por banca examinadora em
de de , conferindo ao autor o título de **Mestre
em Ciências em Engenharia Elétrica.**

Banca Examinadora:

Prof. Dr. João Onofre Pereira Pinto
Prof. Dr. Giscard Francimeire Cintra Veloso

Itajubá

William Henrique Pereira Costa

**Classificação Multiclasse de Sinais de
Eletroencefalograma para Tarefas de Imaginação Motora
utilizando Processamento Estatístico de Sinais e Deep
Learning**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Elétrica como parte dos requisitos para obtenção do Título de Mestre em Ciências em Engenharia Elétrica.

Trabalho aprovado. Itajubá, 27 de julho de 2023:

Prof. Dr. Luiz Eduardo Borges Silva
Orientador

Prof. Dr. João Onofre Pereira Pinto

**Prof. Dr. Giscard Francimeire Cintra
Veloso**

Itajubá
31 de julho de 2023

Agradecimentos

Primeiramente, um agradecimento especial aos meus pais, Andrelina e Gilson, e aos meus irmãos, Bruno e Iasmim, por estarem sempre ao meu lado, me apoiando em todas as etapas.

Agradecimento especial aos meus amigos de república, que foram verdadeiros parceiros nessa caminhada. O Marciano, conhecido como Marte, merece um agradecimento especial por ter me apresentado o IESTI e por todos os trabalhos que realizamos juntos. E não posso esquecer do Diego (Didi), do Jean e do Edson (Bixo), que estiveram comigo nesses intensos dois anos de mestrado, enfrentando todos os desafios ao meu lado.

Quero expressar minha profunda gratidão ao meu orientador, Professor Dr. Luiz Eduardo, pela oportunidade de desenvolver esse trabalho incrível, pela confiança que depositou em mim e pelos conselhos valiosos que sempre me ofereceu.

Também gostaria de agradecer aos Professores João Onofre e Giscard, que dedicaram seu tempo e conhecimento para participar da banca e avaliar esta dissertação. Suas contribuições foram fundamentais.

Por último, mas não menos importante, agradeço à CAPES e ao povo brasileiro pelo financiamento desta pesquisa ao longo de dois anos. Sem esse apoio, eu não teria conseguido realizar esse sonho.

Obrigado a todos por fazerem parte dessa jornada e por tornarem essa conquista possível.

“No dia que paramos de lutar uns pelos outros, perdemos nossa humanidade.”
(Desconhecido)

Resumo

Interesses de pesquisa: A classificação eficiente dos sinais de eletroencefalograma (EEG) é fundamental para a construção de sistemas com interface cérebro-computador. No entanto, a complexidade dos sinais de EEG e sua variabilidade entre indivíduos apresentam desafios significativos para a classificação precisa. Este estudo tem relevância social, pois pode contribuir para o desenvolvimento de interfaces cérebro-computador assistivas, beneficiando pessoas com severos danos motores, como aquelas que sofreram acidente vascular cerebral (AVC). Essas interfaces têm o potencial de melhorar a qualidade de vida desses indivíduos, permitindo a comunicação e o controle de dispositivos através da atividade cerebral.

Objetivos: Este estudo teve como objetivo comparar o desempenho e o custo computacional de uma rede neural artificial utilizando diferentes técnicas de processamento de sinal na classificação de estados de repouso e imaginação do movimento do punho esquerdo e direito a partir de sinais de EEG. Foram exploradas três técnicas estatísticas de processamento de sinais: Análise de Componentes Principais (PCA), Análise de Componentes Independentes (ICA) e Análise Espectral Singular (SSA), em conjunto com uma Rede Neural Convolucional (CNN).

Resultados obtidos: Os resultados obtidos revelaram que a técnica de PCA proporcionou uma redução no tempo de treinamento de até 63,5%, sem comprometer significativamente o desempenho em termos de acurácia na classificação. A PCA demonstrou ser uma abordagem promissora, permitindo a captura de informações relevantes nos sinais de EEG e aprimorando a capacidade da CNN em realizar a classificação com precisão. Por outro lado, as técnicas de ICA e SSA não apresentaram resultados promissores. A ICA teve efeitos negativos na extração de características, resultando em uma diminuição na acurácia da classificação realizada pela CNN. A SSA, por sua vez, mostrou um desempenho geralmente baixo em todas as métricas avaliadas, indicando uma dificuldade em capturar as informações discriminativas presentes nos sinais de EEG-IM.

Palavras-chaves: Eletroencefalograma. Imaginação Motora. Processamento de Biossinais. *Machine Learning. Deep Learning.*

Abstract

Research Interests: Efficient classification of electroencephalogram (EEG) signals is crucial for the development of brain-computer interface systems. However, the complexity and variability of EEG signals pose significant challenges for accurate classification. Additionally, this study has social relevance as it can contribute to the development of assistive brain-computer interfaces, benefiting individuals with severe motor impairments, such as those who have experienced a stroke. These interfaces have the potential to improve the quality of life for these individuals by enabling communication and device control through brain activity.

Objectives: This study aimed to compare the performance and computational cost of an artificial neural network using different signal processing techniques for the classification of resting state and left/right wrist movement imagination states from EEG signals. Three statistical signal processing techniques, Principal Component Analysis (PCA), Independent Component Analysis (ICA), and Singular Spectrum Analysis (SSA), were explored in conjunction with a Convolutional Neural Network (CNN) to enhance the classification of EEG signals.

Results Obtained: The results revealed that the PCA technique led to a reduction in training time of up to 63.5% without significantly compromising performance in terms of classification accuracy. PCA proved to be a promising approach, capturing relevant information from the EEG signals and improving the CNN's ability to classify accurately. On the other hand, both ICA and SSA techniques did not yield promising results. ICA had negative effects on feature extraction, resulting in decreased classification accuracy by the CNN. SSA, on the other hand, showed consistently low performance across all evaluated metrics, indicating challenges in capturing discriminative information from the EEG-IM signals.

Key-words: Electroencephalogram. Motor Imagery. Biosignal Processing. Machine Learning. Deep Learning.

Lista de ilustrações

Figura 1 – Imagem com artefatos provenientes de outras áreas do corpo	18
Figura 2 – Na imagem, observa-se que as áreas ativadas pelo movimento se assemelham com as áreas ativas pela imaginação do movimento.	22
Figura 3 – Fluxograma dos procedimentos metodológicos aplicados no estudo. . .	29
Figura 4 – Posicionamento dos sensores da EEG no escalpo dos voluntários no sistema internacional 10-10, com 64 eletrodos.	30
Figura 5 – Aquisição de sinais EEG durante tarefa de imaginação motora	31
Figura 6 – Recorte de aproximadamente 30 segundos do arquivo <i>raw</i> de um dos voluntários, cada código e cor simboliza um período de realização de uma tarefa.	32
Figura 7 – Gráfico dos sinais da EEG no domínio da frequência após aplicação do filtro passa-faixa entre 0,5 - 40 Hz.	33
Figura 8 – Gráficos com os diferentes janelas de tempo.	33
Figura 9 – Histograma com a distribuição dos dados.	34
Figura 10 – Distribuição dos dados após a normalização <i>z-score</i>	36
Figura 11 – Gráfico com artefatos de EOG	38
Figura 12 – Topografia do escalpo das cinco primeiras CIs.	39
Figura 13 – A imagem apresentada contém uma combinação de gráficos e figuras que permitem analisar a origem da componente	39
Figura 14 – Nesse gráfico, observam-se os sinais após a aplicação da <i>Independent Component Analysis</i> (ICA). Em preto, pode-se visualizar o sinal limpo, com amplitudes suavizadas.	40
Figura 15 – Diagrama com a síntese do algoritmo da <i>Singular Spectral Analysis</i> (SSA). Cada bloco teve suas 64 componentes decompostas individualmente. Para isso, necessitou-se utilizar um laço. Após a decomposição, escolheram-se as componentes que seriam mantidas pela variância e efetuou-se a reconstrução do sinal.	41
Figura 16 – A matriz de trajetória é composta por vetores sendo formados pelos diferentes valores de L e suas séries defasadas. As linhas e colunas são subséries da série original.	42
Figura 17 – No gráfico apresentado, observa-se uma das componentes que correspondia a 86,3% da variância da série original (em azul).	43
Figura 18 – Nesse gráfico, observa-se a primeira componente em relação à série original.	44
Figura 19 – Nesse gráfico, têm-se as duas primeiras componentes somadas e a Componente 2 - SSA em comparação com série original.	44

Figura 20 – Ao comparar a série original com a série acumulada, nota-se uma suavização nos contornos, indicando a eliminação do ruído presente nos sinais.	45
Figura 21 – Imagem referente a uma tarefa contendo 5 s amostrados em 160 Hz. No total, há 64 sensores da EEG e o tamanho da imagem é de 64×801	47
Figura 22 – Imagem após o processamento pela PCA.	47
Figura 23 – Gráfico representando o tempo médio total gasto ao somar as técnicas de processamento e a CNN.	51
Figura 24 – Componentes em ordem - parte 1.	67
Figura 25 – Componentes em ordem - parte 2.	68
Figura 26 – Componentes em ordem - parte 3.	69
Figura 27 – Análise da componente ICA001 revela uma polarização nos sensores da região do Lobo Parietal, indicando atividade cerebral.	70
Figura 28 – Polarização observada no olho esquerdo na componente, indicando movimento muscular, como o fechamento do olho direito.	70
Figura 29 – Polarização específica em um dos sensores na componente ICA003, indicando ruído no sensor.	71
Figura 30 – Componente classificada como "outros", considerada um sinal cerebral sem uma origem específica no cérebro.	71

Lista de tabelas

Tabela 2	– Parâmetros utilizados para o algoritmo de ICA do MNE	38
Tabela 3	– Configurações para a <i>Principal Analysis Component</i> (PCA) em relação à variância.	40
Tabela 4	– Tabela com as diferentes variâncias e suas CPs. Para cada variância diferente, calculou-se o tempo de processamento médio do algoritmo para 20 execuções.	41
Tabela 5	– Componentes em ordem da maior para a menor variância explicada em relação à série original. Os valores são referentes a passagem da SSA por um dos sensores de um dos blocos.	43
Tabela 6	– Arquitetura da <i>Convolutional Neural Network</i> (CNN). Onde C é o número de canais (variável dependo do processamento utilizado), T é o número de ponto na série (801), F_1 é a quantidade de filtros temporais, D é a quantidade de filtros espaciais, F_2 é a quantidade de filtros <i>pointwise</i> e N a quantidade de classes (3).	46
Tabela 7	– Parâmetros utilizados para a configuração da CNN.	46
Tabela 8	– Classificação do coeficiente Kappa	48
Tabela 10	– Resultados dos métodos de processamento	52
Tabela 11	– Resultados encontrados na literatura. Células com “ - ” indicam que a informação não está disponível no trabalho.	56

Lista de abreviaturas e siglas

AVC	<i>Acidente Vascular Cerebral</i>	15
BCI	<i>Brain-Computer Interface</i>	15, 16
CNN	<i>Convolucional Neural Network</i>	10, 11
CSP	<i>Common Spatial Patterns</i>	56
DBN	<i>Deep Belief Network</i>	56
DL	<i>Deep Learning</i>	17, 18
ELA	<i>Esclerose Lateral Amiotrófica</i>	15
fMRI	<i>functional Magnetic Resonance Imaging</i>	17, 25
ICA	<i>Independent Component Analysis</i>	9
IM	<i>Imaginação Motora</i>	16, 17, 20, 22, 23, 27, 53–55, 58, 59
LSTM	<i>Long Short Term Memory</i>	56
ML	<i>Machine Learning</i>	20
MLPNN	<i>Multi-layer Perceptron Neural Network</i>	56
PCA	<i>Principal Analysis Component</i>	11
RNN	<i>Recurrent Neural Network</i>	56
SNC	<i>Sistema Nervoso Central</i>	15
SSA	<i>Singular Spectral Analysis</i>	9
SVD	<i>Singular Value Decomposition</i>	56
SVM	<i>Support Vector Machine</i>	54

Sumário

1	INTRODUÇÃO	15
1.1	Considerações Iniciais	15
1.2	Objetivos e Contribuições	19
1.2.1	Objetivos	19
1.2.2	Contribuições	19
1.3	Organização do trabalho	20
2	FUNDAMENTAÇÃO TEÓRICA	22
2.1	Imaginação Motora	22
2.2	Processamento de Sinais da EEG	24
2.3	Classificação da EEG com <i>Machine Learning</i>	27
3	METODOLOGIA	29
3.1	Dados	29
3.2	Pré-processamento	32
3.3	Processamento Estatístico	37
3.3.1	Análise de Componentes Independentes	37
3.3.2	Análise de Componentes Principais	40
3.3.3	Análise Espectral Singular	41
3.4	<i>Machine Learning</i>	45
4	RESULTADOS E DISCUSSÃO	49
4.1	Análise do Tempo de Processamento e Treinamento	49
4.2	Desempenho dos Métodos de Processamento Estatístico	52
4.2.1	Teste ANOVA	54
4.2.2	Comparação com a Literatura	55
5	CONCLUSÕES	58
5.1	Resumo das Contribuições	58
5.2	Sugestão para Trabalhos Futuros	59
	APÊNDICES	61
	APÊNDICE A – FORMULAÇÃO	62
A.1	Formulação da SSA	62
A.1.1	Decomposição	62

A.1.2	Reconstrução	63
-------	------------------------	----

	ANEXOS	66
--	---------------	-----------

	ANEXO A – COMPONENTES DA ICA	67
--	---	-----------

A.1	Componentes	67
------------	------------------------------	-----------

A.2	Exemplos de Artefatos	69
------------	--	-----------

	REFERÊNCIAS	72
--	------------------------------	-----------

1 INTRODUÇÃO

1.1 Considerações Iniciais

Interface Cérebro-Computador (*brain-computer interface* - BCI) é um sistema que utiliza sinais cerebrais para controlar dispositivos externos, permitindo interação com o ambiente sem o uso das vias convencionais do Sistema Nervoso Central SNC, que são musculares ou hormonais. A atividade cerebral consiste em fenômenos eletrofisiológicos, neuroquímicos e metabólicos, e pode ser quantificada por diversas técnicas de monitoramento. Um sistema BCI mensura os sinais cerebrais produzidos por um usuário, extrai deles características específicas e as traduz em comandos para uma aplicação. Esses comandos são convertidos em ações, como o movimento de uma prótese, cadeira de rodas, robô ou cursor [1], ou o estímulo elétrico direto sobre músculos ou sobre o próprio cérebro [2]. Dessa forma, BCI podem atuar como tecnologias assistivas e de reabilitação em pacientes com severas deficiências motoras, como as resultantes de Esclerose Lateral Amiotrófica (ELA), *Acidente Vascular Cerebral* (AVC) ou lesões medulares. As BCI assistivas visam substituir funções perdidas, como comunicação e movimento, permitindo, por exemplo, o controle sobre dispositivos robóticos. BCI de reabilitação destinam-se a facilitar a recuperação neural em pacientes com dano severo no SNC [3]. Além disso, recentemente tem sido cada vez mais explorado o potencial dos sistemas BCI para outros usos, como monitoração emocional de pacientes [4] e soldados [5], monitoração do estado de vigília de motoristas [6], videogames [7] e controle dos estágios do sono [8].

As BCIs podem ser classificadas quanto à metodologia de aquisição de sinais em invasivas e não invasivas. As BCIs invasivas envolvem a implantação cirúrgica de eletrodos na superfície ou dentro do cérebro e permitem a obtenção de informações detalhadas relativas à atividade sináptica que ocorre em um dado alcance dos eletrodos. Nesse contexto, a atividade elétrica cerebral é obtida através de sondas neurais ou de eletrocorticografia (ECoG). Por outro lado, as BCIs não invasivas não requerem procedimentos cirúrgicos e detectam os sinais cerebrais a partir da superfície do escalpo. Nesse caso, diversas técnicas são capazes de mensurar a atividade cerebral, tais como a eletroencefalografia (EEG) e a magnetoencefalografia (MEG), que medem a atividade eletromagnética gerada pelo fluxo de cargas no tecido neural, a ressonância magnética funcional (*functional magnetic resonance imaging* - fMRI) e a espectroscopia no infravermelho próximo (*near infrared spectroscopy* - NIRS), que consideram a resposta hemodinâmica cerebral, secundária à atividade neuronal, para indicar regiões mais ou menos ativadas. As diferentes técnicas mencionadas possuem vantagens e desvantagens em termos de resolução espacial, resolu-

ção temporal, invasividade, portabilidade e custo. Por essa razão, a eletroencefalografia tem sido a técnica mais utilizada em sistemas de *Brain-Computer Interface* (BCI), como descrito na referência [9].

A eletroencefalografia é uma técnica de registro de ritmos cerebrais, que mede, principalmente, os potenciais elétricos pós-sinápticos de neurônios no córtex cerebral, através de eletrodos posicionados na superfície do crânio. Considerando que os sinais neuronais devem passar através de várias camadas de tecido não neural - como meninges, líquido, osso e pele - para alcançar os eletrodos, é necessária uma grande população de neurônios para gerar um sinal registrável na EEG. Embora a técnica ofereça boa resolução temporal (da ordem de milissegundos), é difícil determinar precisamente a origem da atividade elétrica registrada na EEG, o que resulta em uma resolução espacial relativamente baixa.

Do ponto de vista analítico, a amplitude do sinal da EEG informa o quão sincrônica é a atividade dos neurônios subjacentes aos eletrodos, de modo que uma alta amplitude se correlaciona com alta sincronia, e vice-versa. A execução, a preparação ou a imaginação de um movimento é tipicamente acompanhada por queda na amplitude do sinal em dada faixa de frequência da EEG, fenômeno conhecido por dessincronização relacionada a evento (*event-related desynchronization* - ERD). Seu oposto, o aumento na amplitude, é denominado sincronização relacionada a evento (*event-related synchronization* - ERS), e ocorre no estado relaxado [10]. A faixa de frequência dos ritmos cerebrais se correlaciona, de modo geral, com determinados estados comportamentais: ritmos de baixa amplitude e alta frequência (acima de 8 Hz) estão associados à vigília e estado de alerta ou a estágios do sono em que se sonha (sono-REM). Ritmos de amplitude elevada e baixa frequência (abaixo de 8 Hz) estão associados a estágios do sono sem sonhos (sono não-REM). Os principais ritmos do EEG são classificados nas seguintes faixas (ou bandas) de frequência: delta (δ ; abaixo de 4 Hz), teta (θ ; entre 4 e 7 Hz), alfa (α ; entre 8 e 13 Hz), beta (β ; entre 14 e 30 Hz) e gama (γ ; entre 30 e 90 Hz). Ritmos mu (μ) ocorrem em frequências similares aos ritmos alfa, e a diferença entre eles é basicamente topográfica: enquanto os ritmos alfa ocorrem amplamente no córtex occipital, ritmos mu ocorrem sobre as áreas motoras e somatossensoriais [11]. Por essa razão, ritmos mu são também denominados ritmos sensorimotores (*sensorimotor rhythms* - SMR).

Os potenciais elétricos registrados através de técnicas de eletrofisiologia podem ser espontâneos ou evocados. Potenciais evocados (*evoked potentials* - EPs) são gerados por estímulo sensorial, como luz, som ou pressão, e fundamentam algumas das estratégias mais comuns de geração de sinais cerebrais para BCI, como o P300 que é um EP que ocorre 300 ms após um estímulo sobre o qual o usuário está dirigindo sua atenção - e o potencial evocado visual de estado estacionário (*steady-state visual evoked potential* - SSVEP) - EP por estímulo visual de alta frequência (> 4 Hz) [12]. Outra estratégia comum de geração de sinal é a baseada em imaginação motora (IM).

A imaginação motora, também conhecida como imaginação do movimento, consiste na simulação mental de uma tarefa motora sem sua execução física [13]. É sabido que essa tarefa gera uma diminuição na amplitude de certas bandas de frequência do eletroencefalograma (EEG), como os ritmos μ e β , conhecida como redução de atividade elétrica (ERD). Além disso, estudos com fMRI mostraram que a imaginação motora ativa regiões do córtex motor, pré-motor e somatossensorial de maneira semelhante ao movimento físico,

As BCIs baseadas em IM possuem uma vantagem importante sobre as baseadas em EPs, que é o fato de não requererem um dispositivo externo para gerar os sinais cerebrais. No caso das BCI baseadas, por exemplo, em P300 ou SSVEP, é necessário um monitor de computador, ou LEDs, para dar a dica ao cérebro de que ele deve produzir um determinado tipo de resposta [14]. Se por um lado isso tem a vantagem de não exigir um esforço consciente do usuário, também limita sua capacidade de tomada de decisões. Nas BCIs baseadas em IM, o usuário pode, a princípio, imaginar o que quiser no momento em que quiser, acionando o dispositivo da forma que desejar. Na prática, no entanto, essa tarefa não é tão trivial, pois exige um esforço consciente do usuário, que muitas vezes deve treinar para conseguir aperfeiçoar sua estratégia de geração de sinais [15, 16, 17]. Ademais, as respostas cerebrais relacionadas à IM costumam possuir uma grande variabilidade intra e inter-indivíduos, o que torna a análise dos sinais laboriosa [18]. Apesar das dificuldades, BCI baseadas em IM têm mostrado potencial na reabilitação de pacientes com deficiências motoras, uma vez que o estímulo de regiões cerebrais envolvidas na intenção do movimento incita neuroplasticidade nessas áreas, bem como nas envolvidas na execução do movimento [19].

Por outro lado, recentemente as técnicas de aprendizado de máquina (*machine learning* - ML) baseadas em *deep learning* (DL) vêm obtendo o melhor desempenho em problemas variados de classificação, com destaque para o reconhecimento de objetos [20, 21, 22] e de fala [23, 24]. Segundo a referência [25], “DL permite que modelos computacionais compostos de múltiplas camadas de processamento aprendam representações de dados com múltiplos níveis de abstração”. Além disso, algoritmos de DL possuem uma boa capacidade para generalizar abundância de dados [26] e trabalhar com dados ruidosos [27, 28]. Estas características das técnicas DL as tornam particularmente adequadas para a discriminação de biosinais ruidosos, como é o caso dos sinais da EEG usados em BCI.

Apesar do DL lidar bem com ruídos, e ele propriamente não é um filtro ou mesmo atua na parte de processamento do sinal. Portanto, a utilização de técnicas para eliminar ou minimizar o ruído pode otimizar os resultados do DL [29, 30]. Os sinais da EEG apresentam ruídos, como da rede elétrica, piscadas de olhos, movimentos musculares e batimento cardíaco [31], esses três últimos são conhecidos como artefatos nos sinais da EEG. Na Figura 1 pode-se observar os sinais de outros tipos de artefatos que contaminam

o EEG.

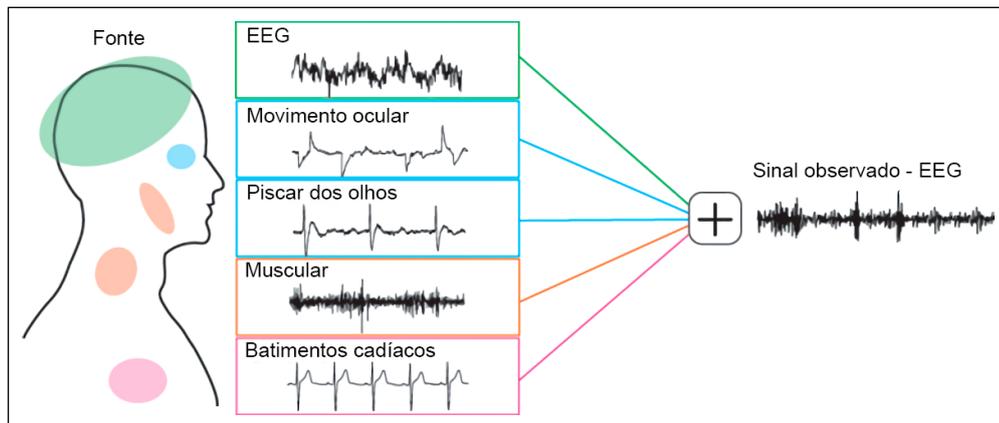


Figura 1 – Nessa imagem, é possível observar a presença de artefatos provenientes de outras áreas do corpo, como os sinais da eletro-oculografia (EOG), relacionados ao movimento dos olhos ou piscar, e os sinais da eletrocardiografia (ECG), relacionados aos batimentos cardíacos. Adaptado de [32].

A Figura 1 ilustra como esses artefatos podem estar presentes no sinal EEG e devido à natureza fraca dos sinais elétricos cerebrais, com amplitudes no nível de microvolts (μV), os sinais EEG são altamente vulneráveis a interferências de ruído, o que aumenta a complexidade do processamento do sinal e requer a remoção destes ruídos antes do processo de DL. Existem várias técnicas de pré-processamento, incluindo *Common Spatial Patterns* (CSP) [31, 33], Análise de Componentes Principais (PCA, de *Principal Component Analysis*) [31], *Common Average Referencing* (CAR) [31], *Surface Laplacian* (SL), filtragem adaptativa [31], Análise de Componentes Independentes (ICA, de *Independent Component Analysis*) e filtros digitais [34].

Dentre as técnicas citadas acima, destacam-se as técnicas do PCA e ICA por serem amplamente utilizadas para tratar os sinais da EEG [35], tais como:

- A ICA é uma técnica importante e destacada para o processamento de sinal. Ela é utilizada para decompor o sinal em componentes independentes. No caso do EEG, a ICA é usada para identificar e remover sinais de fontes externas ao cérebro, como sinais de eletro-oculografia (EOG), eletrocardiografia (ECG), ruído dos sensores, entre outros [35, 36].
- A PCA é um método bem estabelecido e amplamente utilizado em vários campos, como a eletromiografia, para extração de características e redução de dimensionalidade. Em outros campos da biomedicina, a PCA é usada para aumentar a relação sinal-ruído (SNR) em sinais neuro-magnéticos [37]. Na classificação de IM, a PCA pode minimizar o tempo de treinamento de uma rede neural sem perda significativa de informações contidas no sinal [36].

A Análise Espectral Singular (SSA, de *Singular Spectrum Analysis*) é uma técnica que começou a ser explorada a pouco tempo para dados da EEG. A SSA decompõe uma série temporal em componentes que podem ser interpretadas como tendência, periodicidade e ruído. A SSA enfatiza a separação das componentes subjacentes e pode separar as periodicidades que ocorrem em diferentes escalas de tempo, mesmo em dados de séries temporais com muito ruído. Em [38], utilizou-se a SSA para processar e classificar padrões de resposta cardiovasculares na ECG. A referência concluiu que a SSA é uma técnica promissora para o processamento de dados com base em biosinais elétricos.

1.2 Objetivos e Contribuições

1.2.1 Objetivos

Este estudo tem como objetivo avaliar o desempenho e o custo computacional de uma Rede Neural Convolutiva (*Convolutional Neural Network* - CNN) para a classificação de estados de repouso, imaginação do movimento (IM) do punho esquerdo e IM do punho direito, utilizando técnicas de processamento de sinais descritivas, como ICA, PCA e SSA.

Dentro desse contexto, destacam-se os seguintes objetivos específicos:

- Comparar o desempenho de diferentes técnicas de processamento de sinais em conjunto com uma rede neural artificial para a classificação de sinais de eletroencefalograma (EEG) relacionados à imaginação motora.
- Avaliar o impacto dessas técnicas no custo computacional, considerando o tempo de treinamento e a eficiência geral do sistema.
- Investigar a viabilidade dessas técnicas para aplicações práticas, especialmente em sistemas de interface cérebro-computador assistivas.

Esses objetivos visam aprimorar o entendimento sobre o desempenho e a eficiência dessas técnicas, fornecendo *insights* para o desenvolvimento de sistemas de classificação da EEG mais robustos e aplicáveis em diferentes cenários, incluindo BCIs assistivas.

1.2.2 Contribuições

Este estudo oferece as seguintes contribuições:

- Avanço no conhecimento sobre o uso de técnicas de processamento de sinais em combinação com *machine learning* para melhorar a classificação de sinais da EEG relacionados à imaginação motora.
- Comparação e análise de diferentes técnicas de processamento de sinais, como a PCA, ICA e a SSA, para identificar sua eficácia na classificação de sinais da EEG.
- Avaliação do impacto no custo computacional das técnicas de processamento de sinais, fornecendo informações que podem ser usadas para a seleção de abordagens adequadas em termos de desempenho e eficiência.
- Contribuição para o desenvolvimento de sistemas de BCIs assistivas, que podem beneficiar pessoas com deficiências motoras severas, proporcionando maior independência e qualidade de vida.
- Como observado pela referência [35], esse estudo está situado em uma área de fronteira do conhecimento, conferindo relevância às suas contribuições para a comunidade acadêmica, principalmente no que tange a escolha de um método para processamento de sinais EEG-IM.

Essas contribuições são relevantes tanto para a área de processamento de biossinais e ML e para o campo das BCI, fornecendo diretrizes para aprimorar a classificação de sinais da EEG relacionados à IM.

1.3 Organização do trabalho

Neste **Capítulo**, foram apresentados trabalhos e conceitos relacionados aos sistemas BCIs e a utilização de IM para BCIs assistivas. Também foram tratados temas como a utilização de técnicas de *deep learning* para classificação de sinais e a necessidade de se utilizar técnicas de processamento de sinais.

No **Capítulo 2**, são apresentadas as fundamentações teóricas sobre a IM, incluindo conceitos básicos sobre o processamento de sinais através da ICA, PCA e SSA, além de abordar a classificação de sinais da EEG por meio de *machine learning*.

No **Capítulo 3**, é descrita a metodologia utilizada no trabalho, incluindo os softwares e hardwares utilizados, assim como as técnicas de processamento e *deep learning* que foram empregadas.

No **Capítulo 4**, são analisados e discutidos os resultados obtidos com as diferentes técnicas estudadas, e ao final desse capítulo, os resultados são comparados com a literatura existente.

No **Capítulo 5**, são apresentadas as conclusões do trabalho, incluindo contribuições e sugestões para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Nesse capítulo, são apresentados os tópicos teóricos necessários para uma boa compreensão do desenvolvimento deste trabalho. Inicia-se com uma abordagem sobre o tema da IM, seguida por processamentos de sinais da EEG, com ênfase nas técnicas da ICA, SSA e PCA. Por fim, abordar-se o tema da classificação de sinais da EEG com base em técnicas de *machine learning* e a importância dessa técnica para analisar e entender os sinais cerebrais, bem como os desafios que precisam ser superados.

2.1 Imaginação Motora

A IM é o processo pelo qual as pessoas visualizam mentalmente a realização de uma ação motora sem realmente executá-la. É um fenômeno neurocognitivo que ocorre na corteza motora [39] e é importante para o planejamento, aprendizagem e execução de ações motoras.

Ela tem sido estudada utilizando a eletroencefalografia, observa-se em diversos estudos como em [40], [41] e [42] que a atividade cerebral durante a IM é semelhante à atividade cerebral durante a execução real das ações. Durante a IM, é observado aumento de atividade na corteza motora e na área pré-motora, como destacado na Figura 4. Também é observado ativação de redes neurais similares as ativadas durante a execução da tarefa.

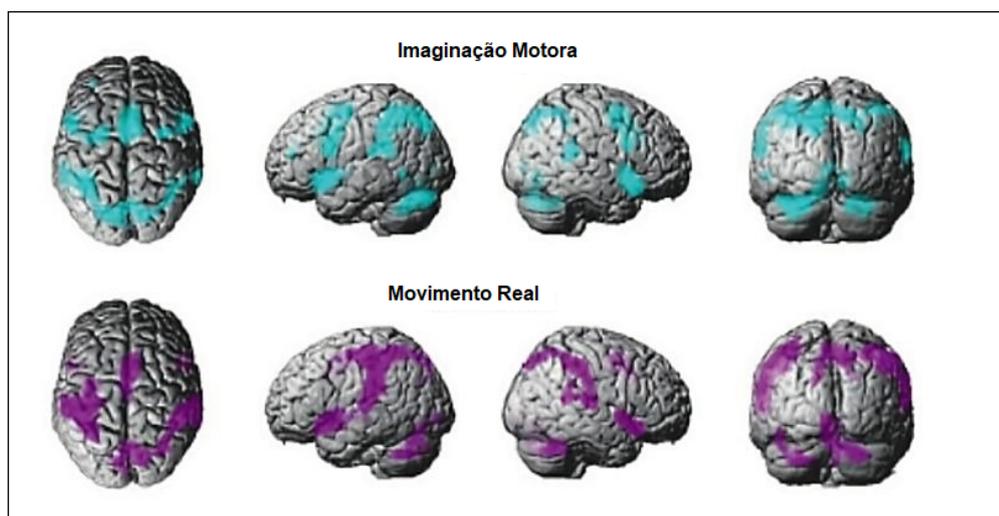


Figura 2 – Na imagem, observa-se que as áreas ativadas pelo movimento se assemelham com as áreas ativas pela imaginação do movimento. Adaptado de [39].

Além disso, a IM tem sido utilizada com sucesso para melhorar o desempenho

motora em indivíduos com lesões cerebrais ou doenças neurodegenerativas, e também para aprimorar habilidades motoras em atletas [43]. A IM pode ser utilizada como uma ferramenta terapêutica para melhorar a recuperação de pacientes com lesões cerebrais e também como um método para melhorar o desempenho motora [44].

Em sistemas BCI, a IM tem sido utilizada como uma forma de comando para sistemas cérebro-computador [13]. O usuário simplesmente imagina realizar uma ação motora específica, como, por exemplo, mover um braço ou uma perna, e essa atividade cerebral é detectada e utilizada para controlar um dispositivo externo.

Um estudo feito por [45] mostrou que a IM pode ser utilizada para controlar dispositivos externos, como, por exemplo, uma cadeira de rodas ou um cursor na tela de um computador. Eles também mostraram que os indivíduos podem ser treinados para controlar dispositivos externos com precisão e velocidade comparáveis às de comandos convencionais.

Em [46] explorou a possibilidade de utilizar a IM para controlar dispositivos externos em pacientes com lesões neurológicas que impedem a realização de ações motoras voluntárias. Os resultados mostraram que a IM pode ser utilizada como uma forma eficaz de comando para sistemas cérebro-computador em pacientes com lesões neurológicas, permitindo-lhes recuperar alguma capacidade de comunicação e controle de dispositivos externos.

Um estudo desenvolvido por [47] utilizou a IM de pessoas que tinham síndrome de encarceramento para controlar um curso na tela de um computador. Na revisão feita por [48] demonstraram que vários estudos caminham para a utilização de sistemas BCI-IM para a reabilitação e recuperação de movimentos de pessoas que tiveram AVC.

Esses estudos sugerem que a IM é uma forma eficaz de controlar dispositivos externos e pode ser utilizada como uma forma de comando para sistemas cérebro-computador. Além disso, os sistemas cérebro-computador baseados em IM são mais discretos e menos invasivos do que os sistemas baseados em outras técnicas, como, por exemplo, a eletroestimulação cerebral.

Em resumo, a IM tem sido amplamente estudada como uma forma de comando para sistemas cérebro-computador, como os estudos mencionados mostram. Ela tem mostrado ser uma forma eficaz de controlar dispositivos externos com precisão e velocidade comparáveis às de comandos convencionais, e também pode ser utilizada por indivíduos com lesões neurológicas que impedem a realização de ações motoras voluntárias.

2.2 Processamento de Sinais da EEG

O processamento de sinais da EEG é uma área importante da neurociência, que envolve a análise matemática e computacional dos sinais EEG para extrair informações sobre a atividade cerebral, como análise de frequência, análise temporal e análise espacial. A análise de frequência é uma técnica que permite avaliar a distribuição de frequências dos sinais EEG, enquanto a análise temporal permite avaliar a dinâmica temporal dos sinais e a análise espacial permite avaliar a distribuição espacial dos sinais.

A análise de frequências permite extrair informações sobre diferentes atividades cerebrais. As bandas de frequência variam em amplitude de diferentes formas durante uma atividade. Por exemplo, a componente alfa da amplitude da EEG aumenta quando fechamos os olhos [49]. Assim, com o processamento, é possível identificar as diferentes bandas de frequência (por exemplo, alfa, beta, gama) que são associadas a diferentes estados mentais ou atividades cerebrais.

Além de extrair informações sobre atividades cerebrais, o processamento de sinais EEG é necessário para remover ruídos dos sinais ou artefatos, como os causados por movimentos dos músculos faciais, oculares e outros músculos próximos aos eletrodos [50, 51], da rede elétrica (50 ou 60 Hz) [52], dos batimentos cardíacos e ruídos ambientais, como música, conversas, etc [53].

No que tange a respeito da extração de características, redução de ruído e de dimensão em dados da EEG, é importante destacar os algoritmos da PCA e ICA [54, 55, 35].

A PCA é frequentemente utilizada para reduzir a dimensionalidade dos dados. É uma técnica de análise de dados multivariadas que tem como objetivo reduzir a dimensionalidade de um conjunto de dados, mantendo ao mesmo tempo, a maior quantidade de informação possível. Ela é amplamente utilizada em diversas áreas, como estatística, ciência de dados, engenharia e biologia. Em sistemas BCI-EEG, ela é apontada por diversos estudos da literatura, como em [56, 35] e [57], como a principal ferramenta para redução de dimensão e ruído em dados da EEG.

A abordagem básica da PCA é relativamente simples e pode ser dividida em etapas principais:

- Centralização dos dados: Os dados são ajustados pela subtração da média, o que permite que a primeira componente principal aponte na direção da maior variabilidade dos dados, em vez de apontar para o centro dos dados.
- Cálculo da matriz de covariância: É realizada a computação da matriz de covariância Σ , com dimensões $d \times d$, utilizando os dados centralizados. Essa matriz

fornece informações sobre a relação entre as variáveis.

- Cálculo dos componentes principais: Os componentes principais são obtidos por meio da decomposição da matriz de covariância em autovetores e autovalores. Os autovetores correspondem aos componentes principais, enquanto os autovalores indicam a quantidade de variação explicada por cada componente principal. Assim, é formada uma matriz A de dimensões $k \times k$, na qual as colunas representam os k autovetores.

A saída dos dados da PCA consiste nas componentes principais, que são selecionadas com base na quantidade de variância explicada. Para uma compreensão mais detalhada sobre os fundamentos teóricos dessa abordagem, é possível consultar os trabalhos de referência [58], [59] e [60]. Esses estudos oferecem informações adicionais relevantes sobre a parte teórica do método.

A ICA é utilizada para separar sinais misturados e entender as fontes independentes de informação presentes nos dados, como, por exemplo, para separar diferentes atividades cerebrais presentes, remoção de artefatos e ruídos. Em [61] utilizou da ICA para remover artefatos de ECG de sinais da EEG de pequenos animais. Já em [62], a ICA foi utilizada para remover artefatos de EOG em dados da EEG.

Além disso, a ICA também é utilizada em outras áreas, como processamento de sinais, análise de imagens e outras. Por exemplo, em [63] a ICA foi utilizada para separar componentes independentes em fMRI. Em [64] a ICA foi utilizada para separar componentes independentes em sinais de áudio misturados.

A ICA é uma técnica de análise de dados multivariadas semelhante à PCA, mas ao invés de buscar vetores que maximizam a variância dos dados, a ICA busca vetores que sejam mutuamente ortogonais e maximizam a independência entre eles. A técnica pode ser resumida através dos seguintes passos:

- Centralização dos dados: os dados são subtraídos da média para evitar que os componentes independentes apontem para o centro dos dados;
- Branqueamento: os dados são transformados para remover a correlação entre as variáveis, ou seja, para torná-las estatisticamente independentes. Isso é feito através de uma transformação linear, como a decomposição de Cholesky, a decomposição de valores singulares (SVD) ou a PCA;
- Aplicação de uma função não-linear: os dados branqueados são aplicados em uma função não-linear, como a função tangente hiperbólica.
- Estimativa das componentes independentes: com os dados branqueados, o algoritmo de ICA estima os vetores de componentes independentes.

- Estimativa dos coeficientes de mistura: os coeficientes de mistura são estimados para reconstruir os sinais originais a partir dos componentes independentes.

Outros detalhes mais aprofundados sobre a técnica da ICA pode ser encontrada nos trabalhos [58], [59] e [60].

A SSA é um método estatístico utilizado para analisar e modelar séries temporais. Ela tem como objetivo decompor a série temporal em componentes estacionários e não-estacionários, buscando identificar os principais padrões de variação presentes na série, como tendências e flutuações. A SSA é uma técnica não-paramétrica, o que significa que não requer nenhuma suposição sobre a distribuição dos dados ou sobre a natureza do processo gerador dos dados. Na área da EEG, a SSA é frequentemente utilizada para identificar padrões de atividade cerebral presentes nos sinais da EEG.

Em 2021, o estudo [65] utilizou um algoritmo composto pela SSA e a ICA para classificar se um indivíduo estava alcoolizado, utilizando-se de dados da EEG. Em [66], a SSA foi utilizada para melhorar a classificação de estágios do sono em dados de eletroencefalografia.

Outros estudos têm explorado o uso da SSA em diversas aplicações. Por exemplo, no estudo feito por [67], a SSA foi utilizada para extrair bandas de frequência que contêm informações para detectar convulsões epiléticas. Em [68], a SSA foi utilizada para remover automaticamente artefatos da EEG.

A técnica pode ser descrita através dos seguintes passos:

- Construção da matriz de Hankel: a série temporal é dividida em janelas e cada janela é colocada como uma coluna na matriz Hankel.
- Decomposição em valores singulares (SVD): a matriz de Hankel é decomposta em valores singulares, o que resulta em três matrizes: uma matriz de autovetores, uma matriz de autovalores e uma matriz de autovetores transpostos.
- Escolha dos componentes: as componentes são escolhidos com base nos autovalores, que representam a variação explicada por cada componente. Nessa fase, efetua-se o agrupamento das séries e identificação das componentes.
- Reconstrução dos sinais: os sinais são reconstruídos a partir das componentes escolhidas.

A fundamentação matemática do algoritmo da SSA é abordada no Apêndice A.1.

A técnica da SSA mostra-se particularmente útil na identificação de padrões estacionários e não-estacionários em séries temporais, além de ser aplicável na remoção de ruídos. Também é utilizada para previsão de séries temporais, detecção de anomalias e

outras aplicações. Ressaltam-se aplicações da SSA em diversas áreas, como climatologia, oceanografia, finanças, entre outras [69].

Em geral, técnicas de processamento de sinais são utilizadas para melhorar a qualidade dos sinais, para entender melhor os padrões presentes, eliminar ruídos e artefatos ou mesmo para facilitar a classificação dos dados. Essas técnicas são frequentemente utilizadas em conjunto, como uma etapa de “pré-processamento” dos dados, antes de aplicar técnicas de classificação, como, por exemplo, nos trabalhos [65] (SSA e ICA), [61] (ICA e PCA) e [68] (SSA e PCA).

2.3 Classificação da EEG com *Machine Learning*

Nos últimos anos, houve avanços significativos no campo do *machine learning*, especialmente com o aumento da capacidade de processamento das GPUs. Devido ao aumento da capacidade de processamento, técnicas de *machine learning* passaram a ser mais atrativas, como redes neurais, máquinas de vetores de suporte (*Support Vector Machine* - SVM) e *Random Forest*. Dentre as técnicas de *machine learning* as redes neurais convolucionais (*Convolutional Neural Network* - CNN) são as arquiteturas mais utilizadas para tarefas de classificação de sinais da EEG [35].

Uma das principais vantagens do uso de técnicas de *machine learning* para classificação da EEG é a capacidade de lidar com grandes quantidades de dados e a capacidade de aprender a partir de exemplos. Além disso, o *machine learning* pode ser usado para lidar com a variabilidade individual, o que é importante para sistemas BCIs.

A classificação da EEG com *machine learning* é utilizada em sistemas BCIs, que visam a criação de comunicação direta entre o cérebro e o computador. O BCI baseado em IM é um exemplo de uma aplicação que tem sido intensamente estudada com o uso de técnicas de *machine learning*. Neste caso, sinais EEG são coletados enquanto o usuário imagina movimentos específicos, e esses sinais são então classificados para determinar qual movimento está sendo imaginado.

Em [70] fizeram uma comparação com vários métodos de *machine learning*, tais como CNN, *long short-time memory* (LSTM) e *deep neural network* (DNN) para reconhecimento de emoções através de sinais da EEG.

A referência [71] apresentou uma rede neural chamada “EEG-Inception” que foi desenvolvida para classificar a IM baseada em sinais da EEG. Essa rede apresentou resultados robustos na classificação de IM se comparados com outros métodos de extração de sinais de IM, conseguindo em média 88,6% de acurácia. Além disso, a rede conseguiu lidar com a variabilidade individual dos voluntários.

Em 2022, a referência [72] apresentou um artigo sobre uma robusta CNN para clas-

sificação de sinais da EEG, a rede mostrou conseguir lidar com a variabilidade individual e inter-sessão, tornando-a uma opção atraente para aplicações clínicas e de pesquisa.

No entanto, a classificação da EEG utilizando técnicas de *machine learning* também enfrenta desafios significativos. Um dos principais desafios é lidar com a variabilidade inter-individual dos sinais da EEG, pois os sinais podem variar significativamente entre indivíduos e até mesmo entre diferentes sessões de registro de um indivíduo. Adicionalmente, a qualidade dos dados da EEG pode ser afetada por artefatos, tais como movimentos oculares e musculares, o que pode afetar a precisão da classificação. Portanto, é crucial aplicar técnicas de pré-processamento e processamento de sinais, para controle de ruídos e a mitigar o a variabilidade inter-individuo, a fim de garantir que os dados sejam precisos e confiáveis [73, 74, 35].

Em síntese, a classificação da EEG com técnicas de *machine learning* têm se tornado cada vez mais popular para analisar e compreender os sinais cerebrais, e tem sido amplamente utilizada em várias áreas de pesquisa. Embora existam desafios a serem superados, as técnicas de *machine learning* têm mostrado ser uma ferramenta eficaz para classificar sinais.

3 METODOLOGIA

No presente capítulo, foram apresentadas as técnicas e metodologias empregadas para o processamento estatístico e para a CNN utilizadas nesse estudo. A apresentação seguiu uma estrutura lógica, demonstrando como a pesquisa foi conduzida.

O fluxograma exibido na Figura 3 ilustra as etapas metodológicas adotadas na pesquisa. Cada fase foi discutida em detalhes nas seções subsequentes.

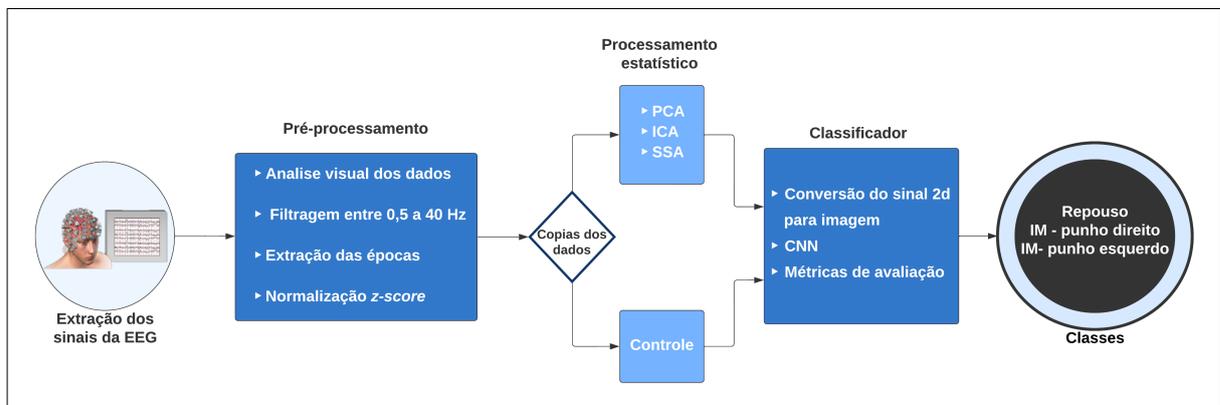


Figura 3 – Fluxograma dos procedimentos metodológicos aplicados no estudo.

Todas as técnicas de processamento e a CNN foram processados em um computador com um processador AMD Ryzen 7 3600x, 32 GB de RAM e uma placa de vídeo Nvidia GTX 1060 com o sistema operacional Microsoft Windows 10 21H2.

3.1 Dados

O banco de dados de imaginação motora utilizado neste trabalho foi disponibilizado pela Physionet [75, 76], constituindo atualmente o maior banco de dados publicamente disponível para pesquisas em interfaces cérebro-computador baseadas em imaginação motora. Este banco de dados consiste em gravações de EEG de 109 voluntários durante a realização de tarefas motoras e imaginação.

Para a aquisição dos sinais EEG, foram utilizados 64 eletrodos com frequência de amostragem de 160 Hz, por meio do sistema BCI2000 [75]. O posicionamento dos eletrodos seguiu o sistema internacional 10-10, conforme ilustrado na Figura 4.

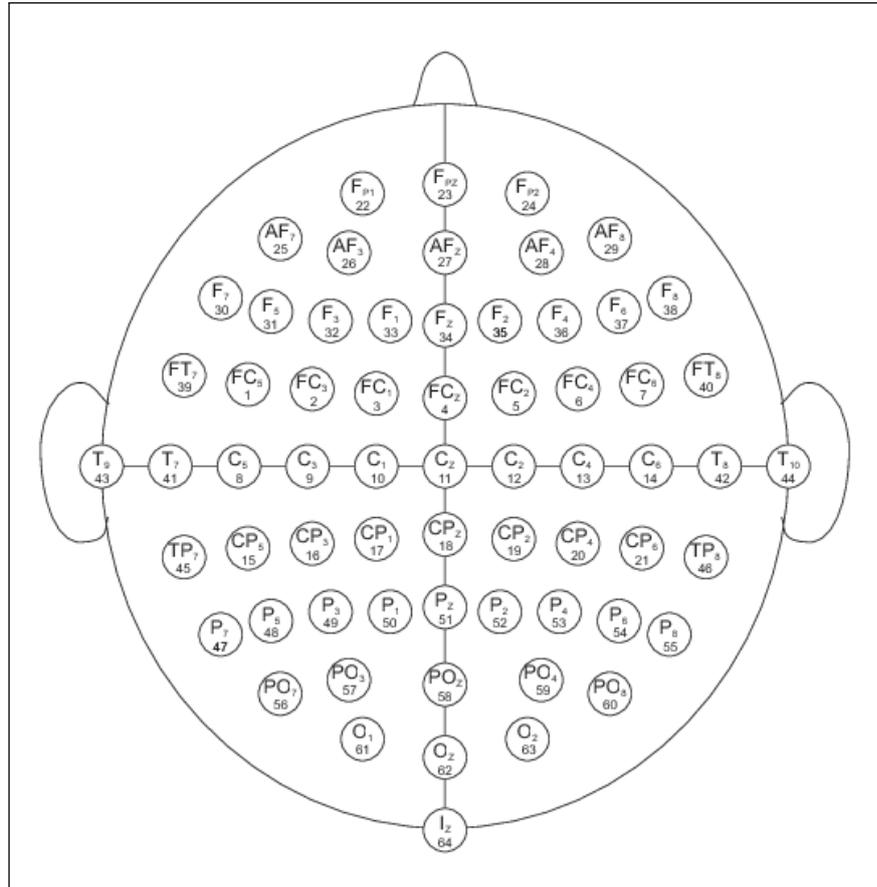


Figura 4 – Posicionamento dos sensores da EEG no escalpo dos voluntários no sistema internacional 10-10, com 64 eletrodos. Imagem da referência [77].

Cada voluntário realizou 14 tarefas experimentais, sendo duas de *baseline*, com duração de 1 minuto cada, para registrar o estado de relaxamento (uma com os olhos fechados e outra com os olhos abertos).

As 12 tarefas restantes, com duração de 2 minutos cada, envolviam diferentes tipos de movimentos imaginados e reais, conforme descrito a seguir:

- Execução real do movimento de abrir e fechar o punho esquerdo ou direito, quando uma seta era apresentada do lado esquerdo ou direito superior da tela;
- Imaginação do movimento de abrir e fechar o punho esquerdo ou direito, quando a seta era apresentada do lado esquerdo ou direito central da tela;
- Execução real de abrir e fechar ambos os punhos simultaneamente, caso a seta aparecesse em ambos os lados superiores da tela, ou abrir e fechar ambos os pés, se a seta aparecesse em ambos os lados inferiores;
- Imaginação do movimento de abrir e fechar ambos os punhos ao mesmo tempo, quando a seta era exibida em ambos os lados central da tela.

Cada uma das tarefas mencionadas acima foi repetida três vezes por cada voluntário submetido ao estudo.

A Figura 5 exemplifica a aquisição dos sinais de EEG durante a realização de uma tarefa de IM de abrir e fechar o punho direito.

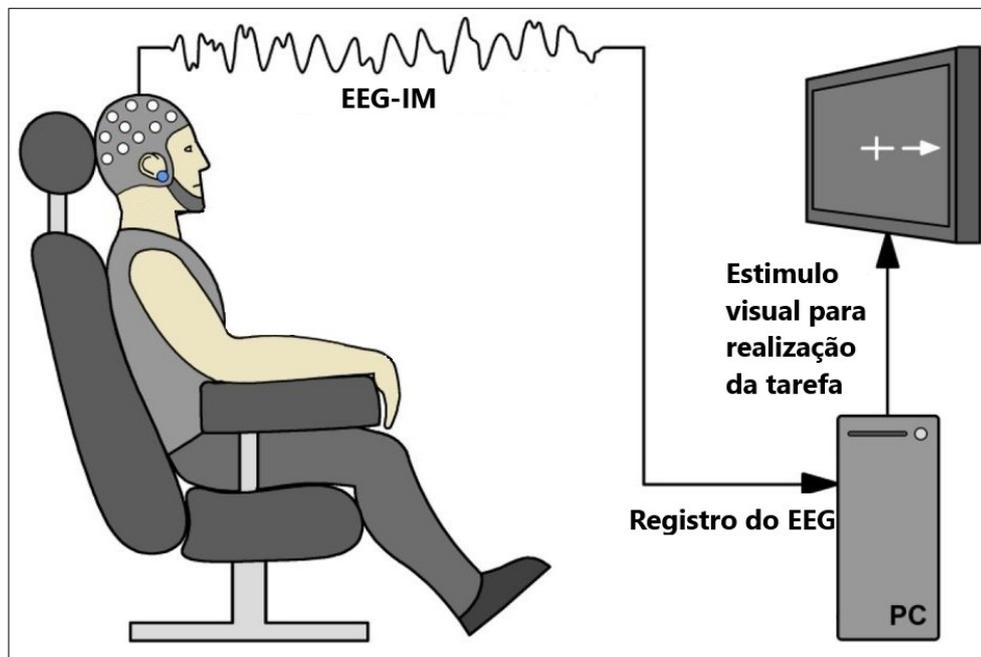


Figura 5 – Aquisição de sinais EEG durante tarefa de imaginação motora. Adaptado de [78].

Neste estudo, foram utilizados especificamente os dados relacionados à tarefa de imaginação do movimento de abrir e fechar o punho esquerdo ou direito.

Para cada aquisição da EEG, havia também um arquivo de anotações indicando o momento em que cada tarefa era solicitada ao voluntário. Essas tarefas receberam codificações específicas:

- T0 - Período de repouso/relaxamento;
- T1 - Imaginação motora do punho esquerdo;
- T2 - Imaginação motora do punho direito.

As anotações com os respectivos códigos das tarefas permitiram identificar e separar os segmentos do sinal EEG associados a cada condição experimental. Isso possibilitou a extração das épocas de interesse para análise.

Na Figura 7, observam-se os sinais da EEG com as marcações referentes às tarefas executadas por um dos voluntários.

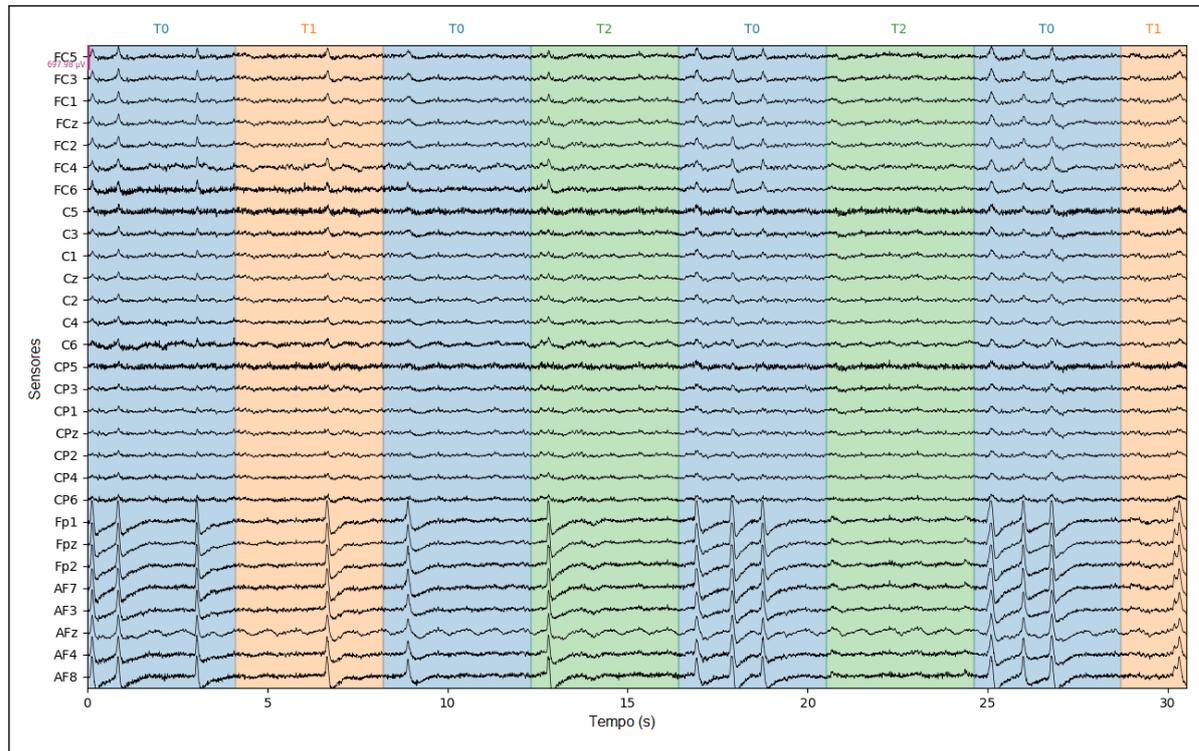


Figura 6 – Recorte de aproximadamente 30 segundos do arquivo *raw* de um dos voluntários, cada código e cor simboliza um período de realização de uma tarefa.

Cada tarefa teve duração de 4,1 s e ao todo foram gravados 124 s, sendo eles distribuídos em 15 de repouso, 7 de IM do punho esquerdo e 8 de IM do punho direito. No total, para cada ensaio foram realizadas, em média, 30 tarefas.

3.2 Pré-processamento

Nessa seção são apresentadas as principais abordagens utilizadas para o tratamento dos dados. Sendo que a primeira etapa consiste em avaliar a qualidade dos registros da EEG dos voluntários, verificam-se possíveis dados corrompidos ou erros no registro do EEG. Para essa etapa, utilizou-se a biblioteca MNE da linguagem de programação Python. Ao analisar os arquivos, verificou-se que os registros dos voluntários 043, 088, 089, 100 e 104 estavam corrompidos e, portanto, não foram utilizados para esse estudo.

Em seguida, aplicou-se um filtro passa-faixa de resposta finita ao impulso (FIR) de segunda ordem entre as frequências de 0,5 a 40 Hz nos registros de cada voluntário. Dentro dessa faixa de frequência, estão presentes as frequências de interesse para a imaginação motora, como a δ (0,5-4 Hz), μ (8-13 Hz) e β (13-30 Hz), essas são as faixas mais efetivas para a imaginação motora encontradas na literatura científica [79, 35]. Na Figura 7 observa-se a resposta dos sinais à passagem do filtro.

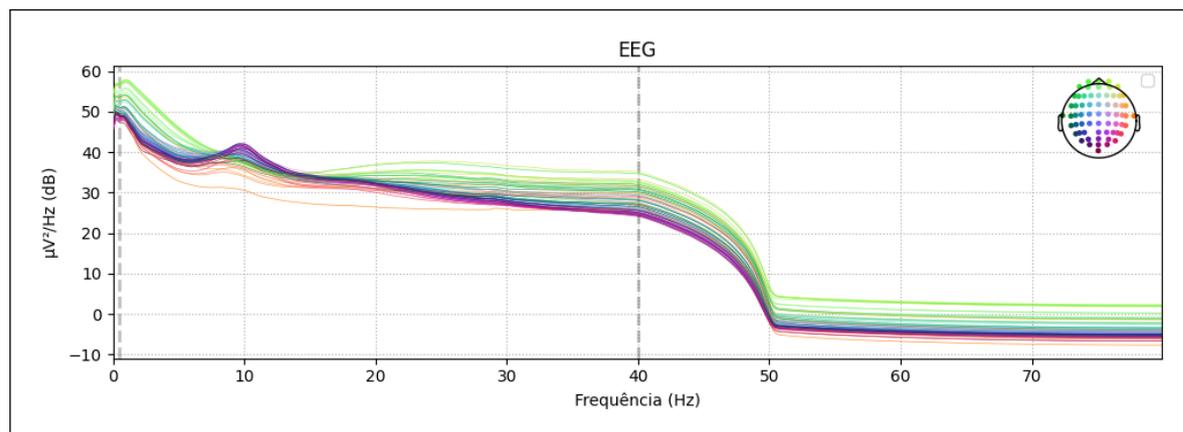


Figura 7 – Gráfico dos sinais da EEG no domínio da frequência após aplicação do filtro passa-faixa entre 0,5 - 40 Hz.

Após a filtragem, verificou-se qual intervalo temporal era adequado para realizar os recortes. O processo de recorte foi considerado delicado devido à variação no tempo de reação entre os voluntários, relativo ao momento em que o alvo é apresentado na tela e à sincronização entre o alvo, as anotações da EEG e a imaginação motora de cada indivíduo. Diante disso, analisaram-se os intervalos com o objetivo de realizar o recorte que contivesse maior quantidade de informações relacionadas à IM. Se o recorte for realizado fora do intervalo de IM, pode haver uma perda de desempenho da rede neural convolucional ou mesmo comprometimento dos métodos de processamento. Para isso, calculou-se a média do sinal para as três tarefas. Observou-se que o intervalo compreendido entre -2 s e 3 s apresentou maior quantidade de informações relacionadas à IM quando comparado com outros intervalos, como pode ser observado na Figura 8.

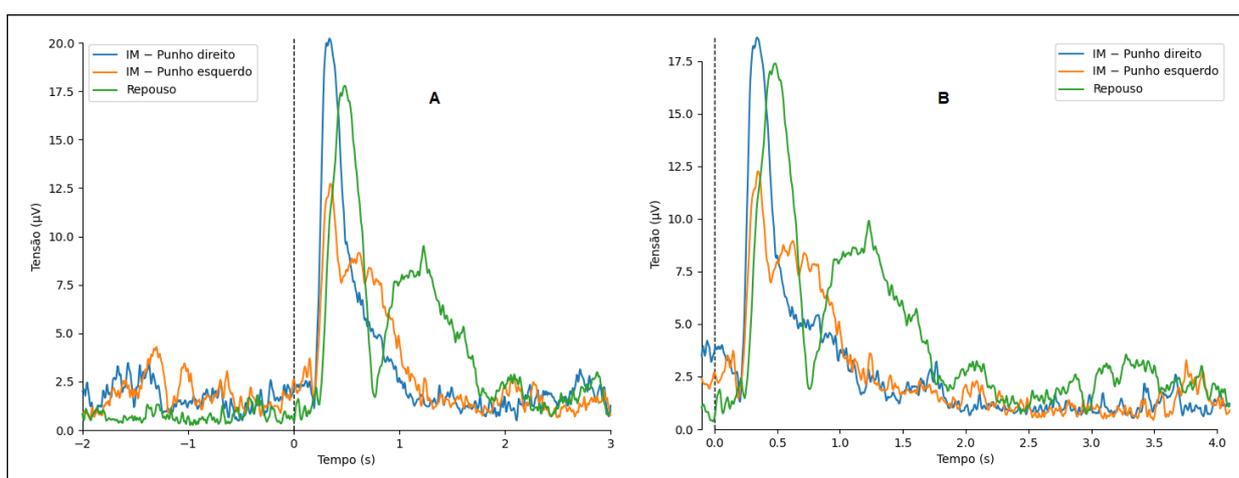


Figura 8 – No gráfico A com janela de -2 até 3 s e no gráfico B tem-se uma janela de -0,1 até 4,1 s. Observa-se que houve picos na amplitude da tensão referente ao IM do punho direito a cerca de -1,5 s. Comparando os dois intervalos observa-se que em A tem-se mais informação relativa a IM do que em B, principalmente antes de a tarefa ser solicitada ao voluntário no tempo 0 s.

Outra etapa fundamental é a verificação da distribuição dos dados, com uma atenção especial à avaliação da normalidade. Em geral, os sinais da EEG não seguem estritamente uma distribuição normal (Gaussiana) devido à presença de atividades cerebrais complexas e à influência de artefatos e ruídos [80, 81, 82]. O histograma representado na Figura 9 pode-se observar a distribuição dos dados.

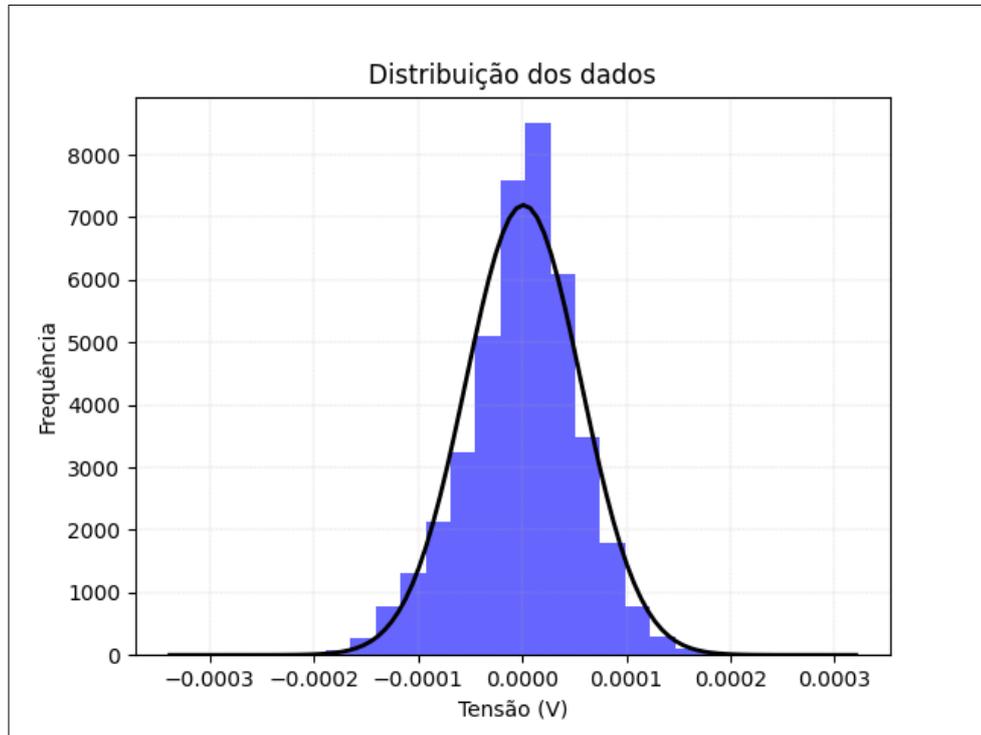


Figura 9 – Histograma com a distribuição dos dados.

Visualmente, observa-se na Figura 9 uma distribuição próxima da normal. Entretanto, inspeções visuais podem ser falhas, necessitando de testes quantitativos.

Dessa forma, para uma confirmação mais objetiva da normalidade dos dados, utilizou-se o teste de D'Agostino-Pearson [83] por meio da função `scipy.stats.normaltest` [84]. Esse teste avalia assimetria (*skewness*) e curtose para quantificar desvios da normalidade.

As hipóteses consideradas foram:

$$H_0 : \text{distribuição normal}$$

$$H_1 : \text{distribuição não normal}$$

Com nível de significância $\alpha = 0,05$ e valor-p obtido de $4,98 \times 10^{-231}$, rejeita-se a hipótese nula (H_0), confirmando que os dados não seguem distribuição normal, conforme inicialmente esperado para sinais EEG.

Ressalta-se que os algoritmos da PCA, SSA e ICA são métodos amplamente utilizados na análise de sinais e não requerem a suposição de uma distribuição normal (Gaussiana) dos dados. Essas técnicas são capazes de realizar o processamento e extrair informações relevantes independentemente da distribuição específica dos dados [85, 86, 87].

A última parte do pré-processamento consiste em normalizar os dados. Isso foi preciso devido às diferenças de escalas entre sensores e entre os sinais dos voluntários. Existem várias razões para utilizar a normalização nos dados. Algumas das principais são:

- Comparabilidade: a normalização permite que dados de diferentes variáveis ou amostras sejam comparados diretamente, pois eles estão na mesma escala. Isso é especialmente útil quando se deseja comparar dados de diferentes fontes ou quando as variáveis têm escala diferentes.
- Algoritmos de análise: muitos algoritmos de análise, como o agrupamento, a regressão e a análise discriminante, requerem que os dados estejam normalizados para funcionar corretamente. Isso é por esses algoritmos serem baseados na distância euclidiana, afetada pelas escalas das variáveis.
- Remoção de *outliers*: a normalização pode ajudar a identificar e remover *outliers* (valores anômalos/discrepantes) nos dados, pois esses valores tendem a se destacar quando os dados estão normalizados.
- Melhora da precisão: a normalização pode melhorar a precisão dos resultados das análises, pois minimiza o impacto da escala dos dados na análise.

A normalização é fundamental para facilitar a comparação e análise de dados, permitindo que eles sejam comparados diretamente, e é uma etapa necessária para a aplicação de algoritmos de análise estatística, remoção de valores atípicos e melhoria da precisão dos resultados. Quanto às redes CNNs, a normalização reduz a variabilidade das entradas, acelerando o treinamento e permitindo que o algoritmo alcance uma solução ótima mais rapidamente. A normalização também evita problemas como a saturação dos neurônios. Para o processo de normalização dos dados, utilizou-se a *z-score* [88], representada na Equação 3.1:

$$Z_k = \frac{X_k - \mu}{\sigma} \quad (3.1)$$

Onde Z_k são os novos valores normalizados e X_k são os valores antigos, μ é a média e σ é o desvio padrão.

Essa equação normaliza os dados subtraindo a média e dividindo pelo desvio padrão. O resultado é que os dados normalizados têm média igual a 0 e desvio padrão igual a 1.

A normalização *z-score* faz com que os dados tenham distribuição com média zero e desvio padrão um. Portanto, após a normalização, espera-se que:

- A média dos dados seja próxima de zero.
- A maioria dos valores estejam entre -1 e 1 (dentro de um desvio padrão da média).
- Aproximadamente 95% dos valores estejam entre -2 e 2 (dentro de dois desvios padrão).
- Valores extremos sejam menos prováveis, mas possíveis.

O gráfico da Figura 10 ilustra essa distribuição normalizada resultante da transformação *z-score* aplicada aos dados.

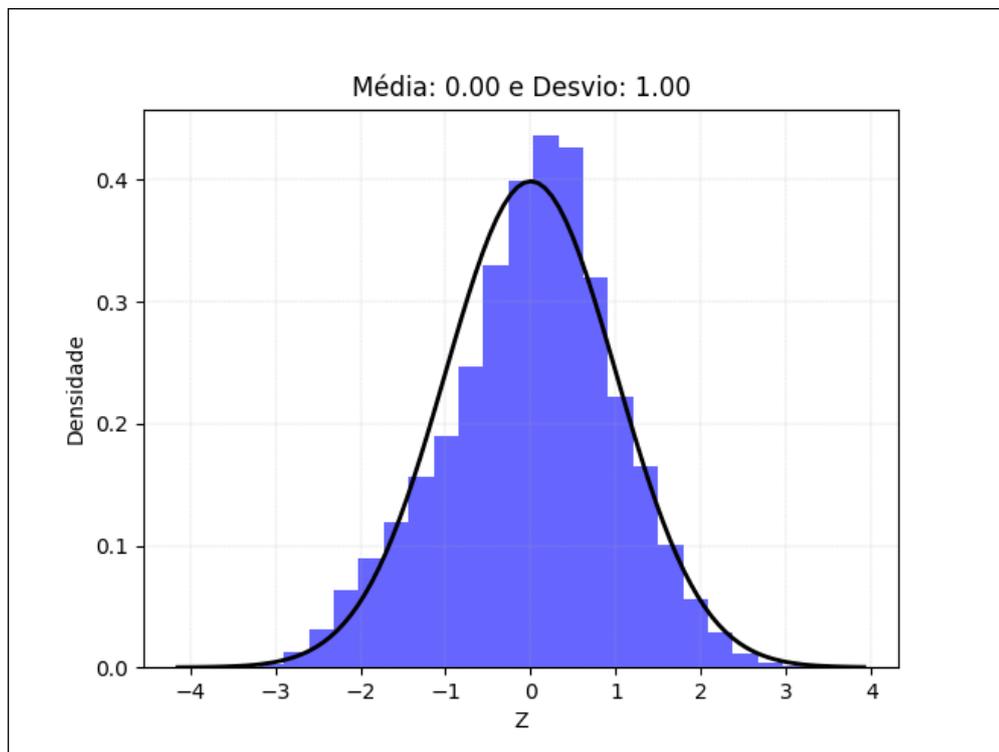


Figura 10 – Distribuição dos dados após a normalização *z-score*.

Após a realização da normalização *z-score*, o pré-processamento dos dados foi finalizado com a criação de duas cópias do conjunto de dados normalizados:

- Conjunto de controle: utilizado sem modificações adicionais para treinar as redes neurais CNN e estabelecer uma referência de base do desempenho.
- Conjunto de processamento: submetido a técnicas de processamento estatístico, como PCA, ICA e SSA, visando avaliar o impacto no desempenho do classificador CNN em comparação ao conjunto de controle.

Essa abordagem de manter um conjunto controle e outro para processamento visa quantificar os efeitos das técnicas estatísticas por meio de uma análise comparativa sistemática dos resultados. Assim, pode-se investigar mais robustamente a influência no desempenho preditivo do modelo de *deep learning*.

3.3 Processamento Estatístico

Nesta seção, descrevem-se os métodos de processamento utilizados neste estudo. Os métodos empregados foram a Análise de Componentes Independentes, a Análise de Componentes Principais e a Análise Espectral Singular. Todos os algoritmos foram implementados utilizando a linguagem Python com códigos de fonte abertos. Para garantir consistência estatística, cada algoritmo foi executado 20 vezes. Nas próximas seções, serão detalhados cada um dos métodos e como foram aplicados.

3.3.1 Análise de Componentes Independentes

A Análise de Componentes Independentes (ICA) tem como objetivo nesse estudo eliminar os artefatos e ruídos que contaminam os dados da EEG. Os artefatos são relacionados às atividades cerebrais que geram sinais registrados no eletroencefalograma, tais como piscar de olhos, movimento muscular do pescoço, entre outros. A ICA permite separar esses sinais em componentes individuais e eliminar os sinais provenientes desses artefatos. Inicialmente, foram analisadas as médias dos sinais no intervalo de cada tarefa (5 segundos) a fim de identificar possíveis artefatos, conforme ilustrado na Figura 11.

Na biblioteca MNE, existe um módulo específico para aplicar a ICA em dados da EEG, a documentação dessa biblioteca está disponível em [89]. Para executar o módulo da ICA, é necessário configurar alguns parâmetros que estão disponíveis na Tabela 2.

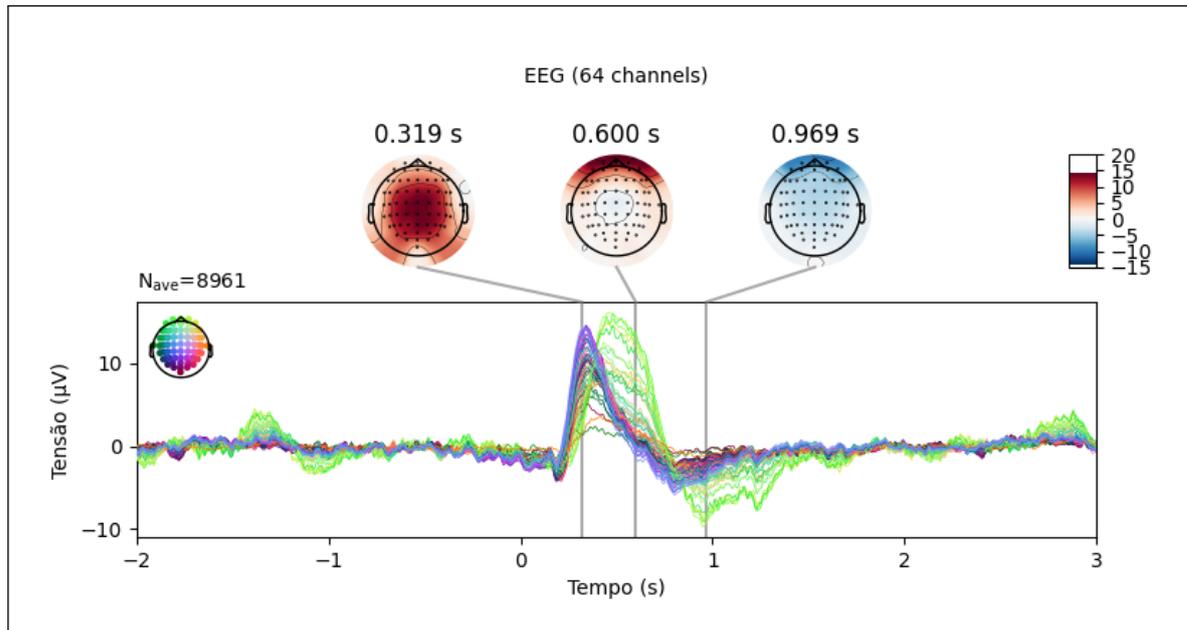


Figura 11 – Na análise está figura, é possível observar que aproximadamente 0,6 segundos após a solicitação da tarefa ao voluntário, ocorre uma intensa polarização nos sensores próximos aos olhos, seguida de uma despolarização na mesma região em 0,969 segundos. Os sensores representados pela cor verde, localizados próximos aos olhos, apresentam picos mais acentuados nessas áreas, indicando que esses sinais são provenientes de atividade ocular (EOG). Esses artefatos oculares podem ser identificados devido às suas características temporais distintas, o que facilita sua separação dos outros sinais cerebrais.

Tabela 2 – Parâmetros utilizados para o algoritmo de ICA do MNE. O parâmetro *n_components* define a variância da PCA, pois o algoritmo de ICA do MNE utiliza a PCA como método de branqueamento. O parâmetro *method* se refere ao método que será utilizado para o ajuste, no caso, o método de *Preconditioned ICA for Real Data (Picard)* [90] foi o mais rápido nos testes realizados. O parâmetro *max_iter* representa o número máximo de iterações durante o ajuste.

Parâmetro	Configuração
<i>n_components</i>	0.99
<i>method</i>	picard
<i>max_iter</i>	200

Com o ajuste, obtiveram-se as componentes independentes (CIs). No entanto, foi necessário realizar uma inspeção visual para identificar e rejeitar as componentes independentes que continham artefatos [91]. As cinco primeiras CIs são demonstradas na Figura 12.

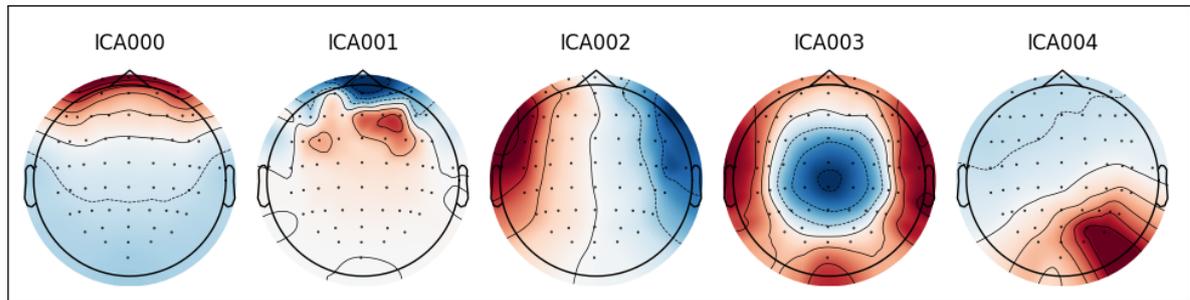


Figura 12 – Topografia do escalpo das cinco primeiras CIs. As componentes ICA000 e ICA002 demonstram atividades de polarização ou despolarização nos eletrodos próximos aos olhos, portanto essas componentes são artefatos de EOG [92, 93]. No entanto, as componentes ICA001 e ICA003 contêm sinais originários no cérebro. Outras componentes estão disponíveis na seção A.1 [94].

A biblioteca MNE oferece a opção de analisar cada uma das CIs, com isso, foi possível comparar as informações dos registros com a literatura. Um exemplo é demonstrado na Figura 13.

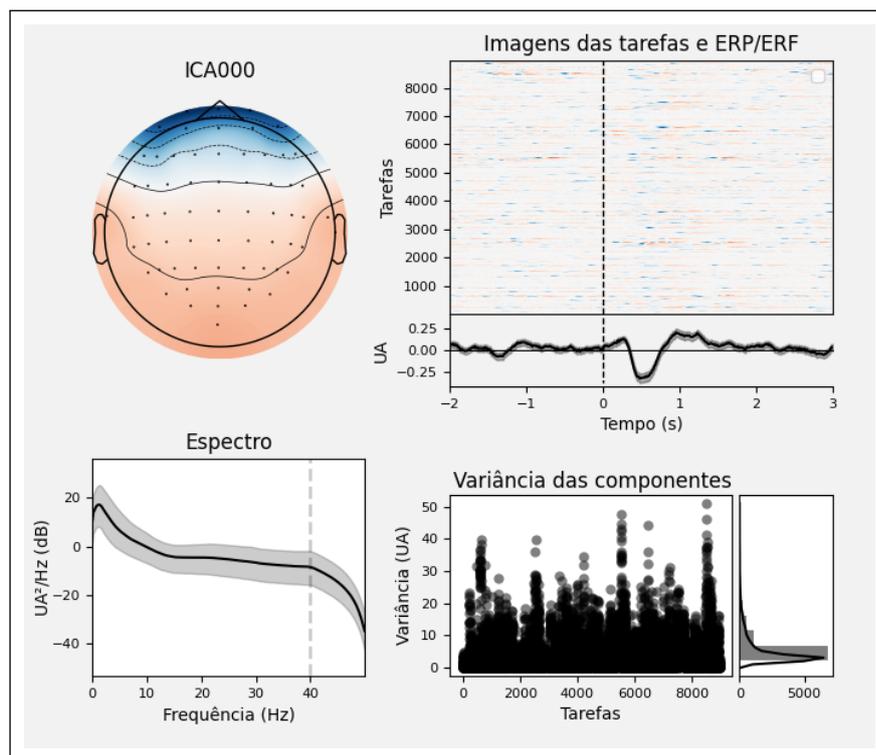


Figura 13 – A imagem apresentada contém uma combinação de gráficos e figuras que permitem analisar a origem da componente. A análise da componente ICA000 revela que há despolarização na região dos olhos. A análise do gráfico de espectro mostra uma concentração em 3 Hz. Como observado em referências, como [95], concentrações em baixas frequências, inferiores a 5 Hz, são indicativas de movimento dos olhos quando observada polarização ou despolarização na região dos olhos. Outras figuras com artefatos e sua identificação estão disponíveis na seção A.2.

Após a análise realizada, excluíram-se as componentes que continham artefatos dos registros da EEG, como ilustrado na Figura 14. Os dados limpos foram então salvos para serem utilizados na CNN (seção 3.4).

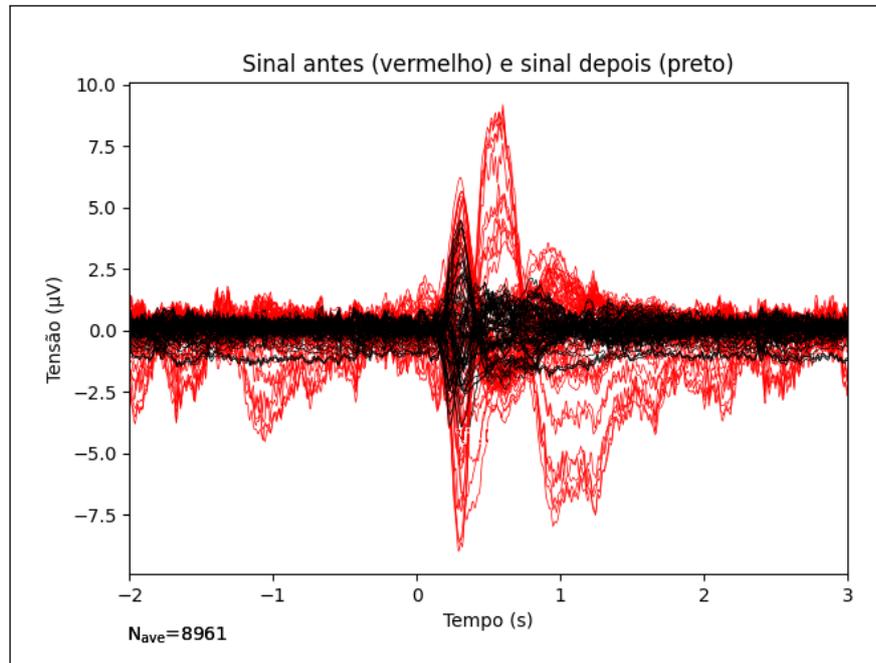


Figura 14 – Nesse gráfico, observam-se os sinais após a aplicação da ICA. Em preto, pode-se visualizar o sinal limpo, com amplitudes suavizadas.

3.3.2 Análise de Componentes Principais

A PCA é uma técnica de redução de dimensionalidade que pode ser usada para selecionar variáveis com base na sua correlação com as outras variáveis do conjunto de dados. Essa técnica pode ser usada para reduzir a dimensionalidade de um conjunto de dados, ou seja, para selecionar apenas as variáveis que mais contribuem para a variância do conjunto de dados. Para esse trabalho, utilizou-se a PCA de maneira a reduzir a quantidade de componentes dos dados, utilizando-se a biblioteca *Scikit-learn* [96]. Para executar o algoritmo necessitou-se configurar o parâmetro *n_components*, esse parâmetro refere-se a quantidade de componentes ou qual a porcentagem da variância explicada deverá ter na saída dos dados.

Tabela 3 – Configurações para a PCA em relação à variância.

<i>n_components</i>	Variância Representada
0,99	99%
0,95	95%
0,90	90%

Após a configuração dos valores, obteve-se a redução das componentes, que inicialmente eram 64 componentes. Como pode ser observado na Tabela 4.

Tabela 4 – Tabela com as diferentes variâncias e suas CPs. Para cada variância diferente, calculou-se o tempo de processamento médio do algoritmo para 20 execuções.

Variância	CP	Tempo de processamento médio (s)
99%	47	40 ± 1
95%	18	41 ± 1
90%	7	40 ± 1

O algoritmo da PCA seleciona o número de componentes necessárias para explicar a variação cumulativa dos dados. Considere este exemplo: têm-se três componentes, sendo que a primeira explica 70%, a segunda explica 20% e a terceira explica os 10% restantes da variância. Se o *n_components* foi configurado para 0,95 (correspondente a 95% da variância explicada), ele seleciona somente as duas primeiras componentes, que explicam 90% da variância. Então, o algoritmo utiliza somente as componentes que atingem o limite solicitado de 95% da variância. A terceira componente, por outro lado, é excluída. Após o processo, os dados foram salvos e utilizados na CNN.

3.3.3 Análise Espectral Singular

Nesse trabalho, utilizou-se a SSA para suavizar as séries temporais através da remoção do ruído. Além da remoção dos ruídos, também verificaram-se as componentes que poderiam ter algum tipo de informação de IM dos voluntários. Para isso, utilizou-se um algoritmo baseado em [97, 98] para a implementação da SSA. Na Figura 15 há uma síntese do algoritmo utilizado e os passos são descritos logo abaixo.

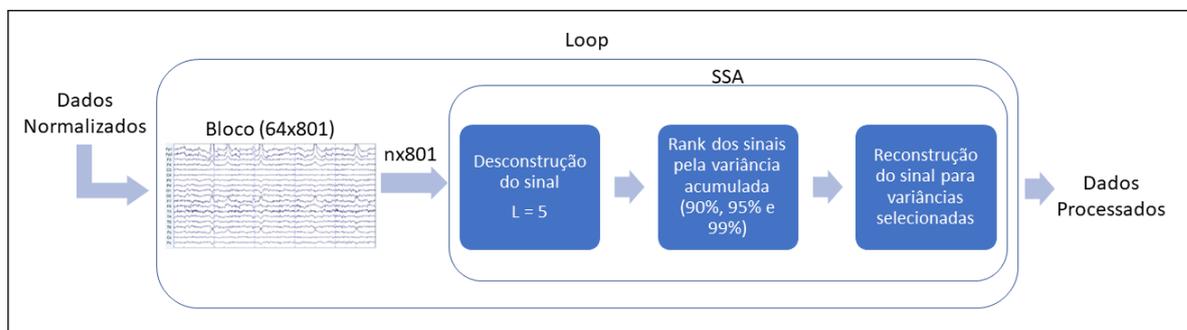


Figura 15 – Diagrama com a síntese do algoritmo da SSA. Cada bloco teve suas 64 componentes decompostas individualmente. Para isso, necessitou-se utilizar um laço. Após a decomposição, escolheram-se as componentes que seriam mantidas pela variância e efetuou-se a reconstrução do sinal.

A primeira parte do algoritmo consiste na transformação da série temporal para a matriz de trajetória¹ [69]. Para essa parte houve necessidade de ajustar o tamanho da janela L , que deve estar contida no intervalo $2 \leq L \leq \frac{N}{2}$ segundo Golyandina [99], o valor dentro desse intervalo minimiza os erros de reconstrução da série ao todo.

O parâmetro L controla o tamanho da matriz de trajetória, sendo o *shape* da matriz dado por (L, K) , onde $K = N - L + 1$ e N é o tamanho da série. Quanto maior o valor de L , mais componentes serão geradas no SSA.

Na Figura 16 há um exemplo desse processo em Python:

```

N = 20 # tamanho da série
L = 5 # tamanho da janela de defasagem

# Gera uma série temporal com N valores
serie = np.arange(N)

print("Série original: ", serie)
print("")

# Calcula a matriz de trajetória no formato de Hankel
trajmat = scipy.linalg.hankel(serie, np.zeros(L)).T

trajmat = trajmat[:, :(N- L + 1)]

for i in range(L): # laço para imprimir as série temporais
    print("L = ", i , '', trajmat[i])

```

output:

```

Série: [ 0  1  2  3  4  5  6  7  8  9 10 11 12 13 14 15 16 17 18 19]
L = 0 [ 0.  1.  2.  3.  4.  5.  6.  7.  8.  9. 10. 11. 12. 13. 14. 15.]
L = 1 [ 1.  2.  3.  4.  5.  6.  7.  8.  9. 10. 11. 12. 13. 14. 15. 16.]
L = 2 [ 2.  3.  4.  5.  6.  7.  8.  9. 10. 11. 12. 13. 14. 15. 16. 17.]
L = 3 [ 3.  4.  5.  6.  7.  8.  9. 10. 11. 12. 13. 14. 15. 16. 17. 18.]
L = 4 [ 4.  5.  6.  7.  8.  9. 10. 11. 12. 13. 14. 15. 16. 17. 18. 19.]

```

Figura 16 – A matriz de trajetória é composta por vetores sendo formados pelos diferentes valores de L e suas séries defasadas. As linhas e colunas são subséries da série original.

Observa-se, que quanto maior for L , maior será a matriz de trajetória e com isso, maior o consumo de memória RAM. Devido ao limite computacional, utilizou-se o $L = 5$.

Além do parâmetro L , definiu-se o método pelo qual as componentes geradas pela SSA foram ranqueadas, para isso utilizaram-se as variâncias de 90%, 95% e 99%.

Após a definição dos parâmetros, a matriz de trajetória foi decomposta pelo algoritmo de decomposição em valores singulares (SVD, de *Singular Value Decomposition*), a finalidade do SVD é reduzir a dimensão dos dados.

¹ Essa matriz é uma matriz de Hankel [69].

A próxima parte do algoritmo consiste em reconstruir as componentes, para isso ele reverte o processo *hankelização* utilizando-se da *diagonal averaging* [100]. Com as componentes reconstruídas é possível fazer o ranqueamento baseado na variância, como pode ser observado na Tabela 5

Tabela 5 – Componentes em ordem da maior para a menor variância explicada em relação à série original. Os valores são referentes a passagem da SSA por um dos sensores de um dos blocos.

Componentes Ordenadas	Variância
0	0.863
2	0.082
4	0.031
5	0.028
3	0.004

Com os dados da tabela, pode-se comparar as componentes com a série original, na Figura 17 observa-se uma das componentes geradas pela SSA.

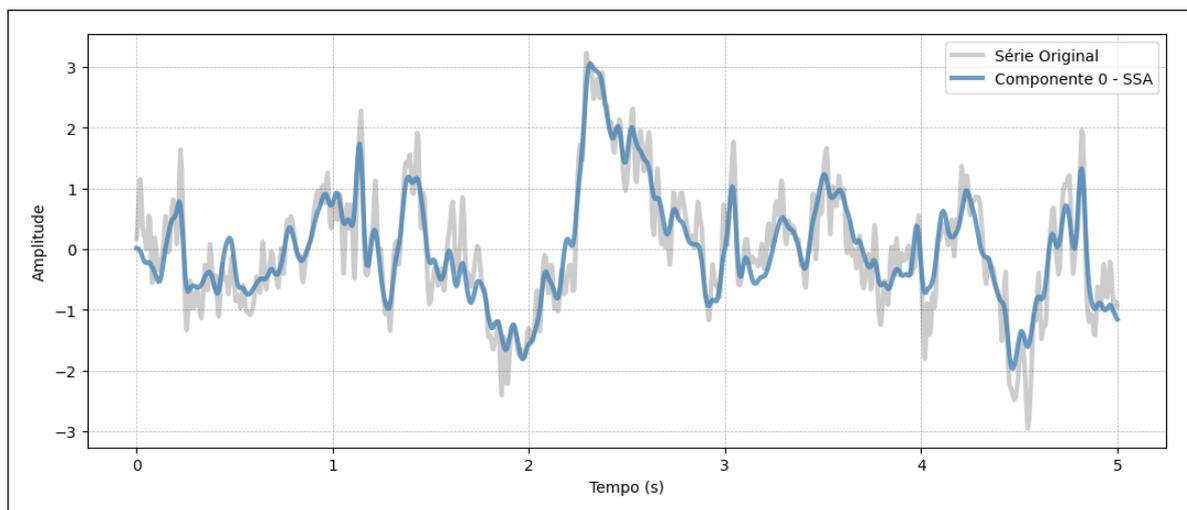


Figura 17 – No gráfico apresentado, observa-se uma das componentes que correspondia a 86,3% da variância da série original (em azul).

Por fim, efetua-se a reconstrução da série, nessa etapa é feita a soma das componentes que representam a variância a qual foram usadas nesse trabalho, dessa maneira elimina-se uma parte do ruído, como pode ser observado na comparação da Figura 18, Figura 19 e Figura 20. O algoritmo de SSA foi aplicado de forma eficaz para remover ruídos das séries temporais dos voluntários.

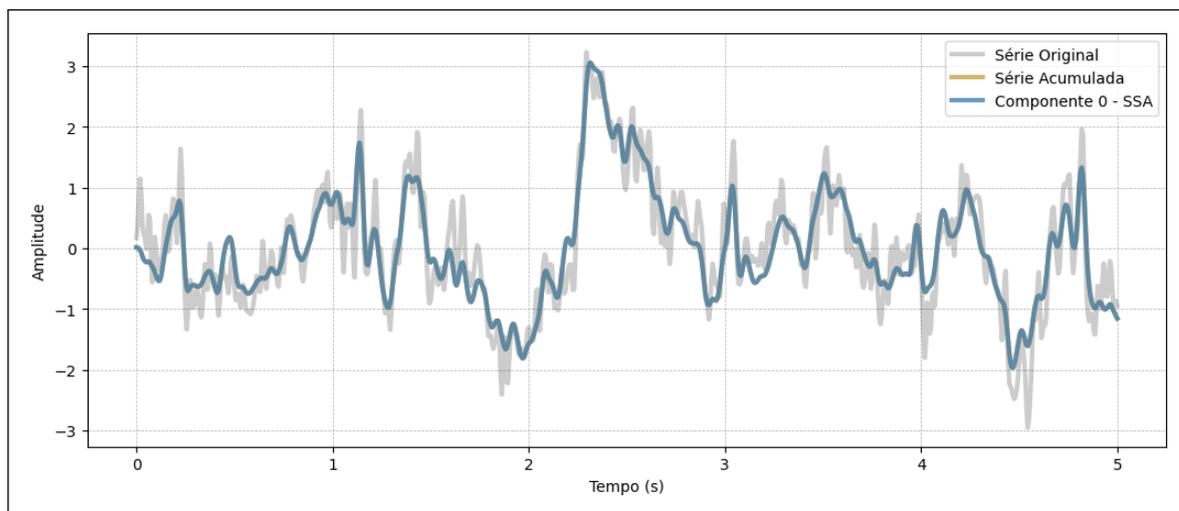


Figura 18 – Nesse gráfico, observa-se a primeira componente em relação à série original.

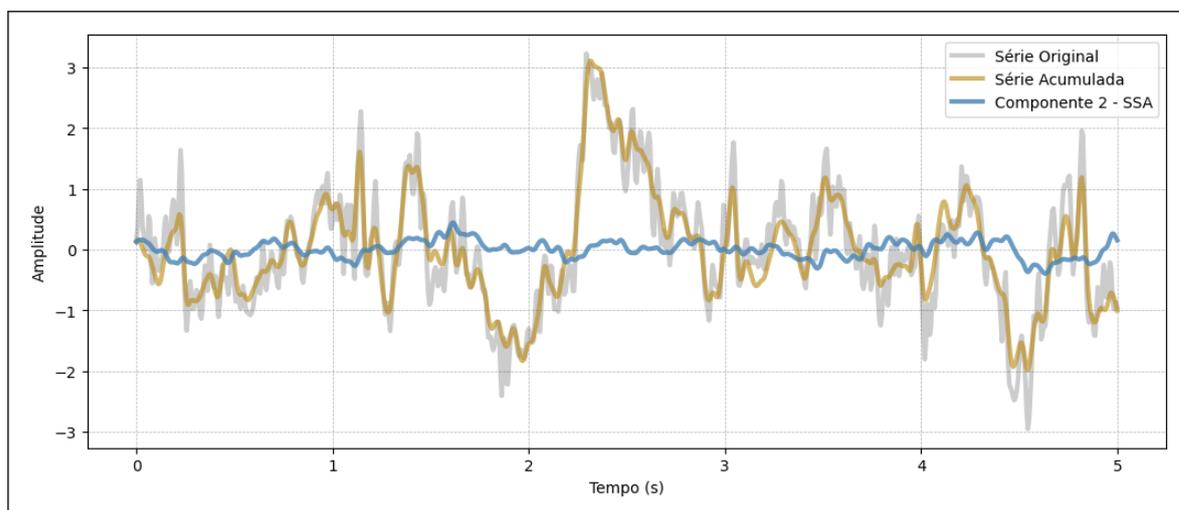


Figura 19 – Nesse gráfico, têm-se as duas primeiras componentes somadas e a Componente 2 - SSA em comparação com série original.

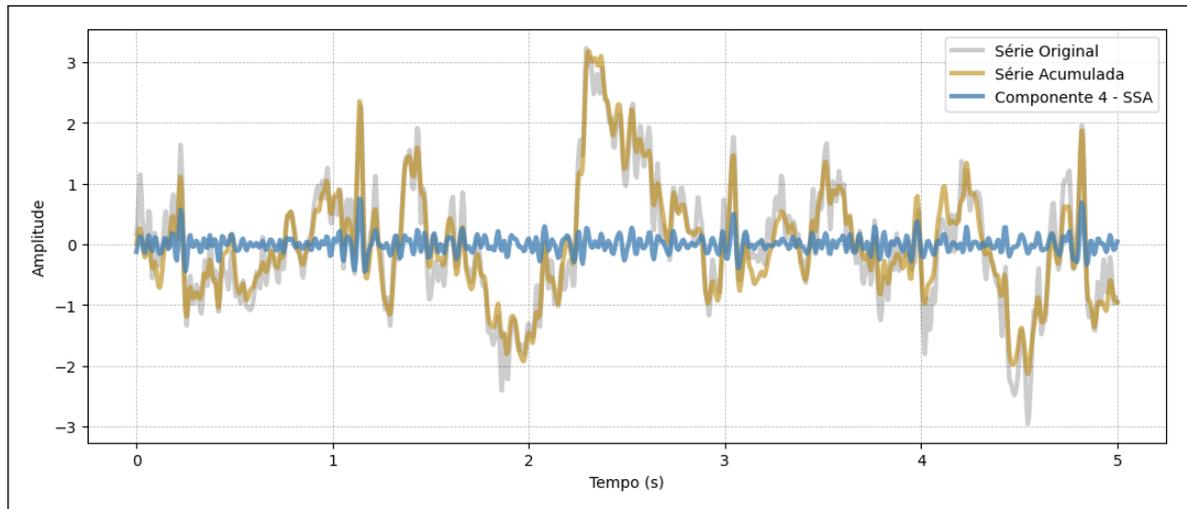


Figura 20 – Ao comparar a série original com a série acumulada, nota-se uma suavização nos contornos, indicando a eliminação do ruído presente nos sinais.

3.4 *Machine Learning*

Neste estudo, utilizou-se uma rede neural convolucional para o *machine learning*. Sua arquitetura foi baseada em uma rede neural compactada desenvolvida por Lawhern et. al., [101]. A implementação da CNN foi realizada utilizando a biblioteca Keras [102] e o TensorFlow [103], ambos em Python. A execução da CNN foi realizada em uma placa de vídeo NVIDIA GTX 1060 com 6 GB de memória utilizando-se da biblioteca cuDNN [104]. É importante destacar que o uso de placas de vídeo para acelerar o treinamento de redes neurais é hoje um pré-requisito para o uso em grandes bancos de dados. A arquitetura da rede pode ser observada na Tabela 6.

Tabela 6 – Arquitetura da CNN. Onde C é o número de canais (variável dependo do processamento utilizado), T é o número de ponto na série (801), F_1 é a quantidade de filtros temporais, D é a quantidade de filtros espaciais, F_2 é a quantidade de filtros *pointwise* e N a quantidade de classes (3).

Blocos	Camadas	Filtros	Tamanho	Ativação
1	Input			
	Reshape			
	Conv2D	F_1	(1,64)	Linear
	BatchNorm			
	DepthwiseConv2D	$D \cdot F_1$	(C, 1)	Linear
	BatchNorm			
	Activation			GELU [105]
	AveragePool2D		(1,4)	
	Dropout			
	2	SeparableConv2D	F_2	(1,16)
BatchNorm				
Activation				GELU [105]
AveragePool2D			(1,8)	
Dropout				
Classificador	Dense	$N \cdot (F_2 \cdot \frac{T}{32})$		Soft-max

Para otimizar os hiperparâmetros, utilizou-se o algoritmo de Otimização Bayesiana baseado na biblioteca Hyperopt do Python [106]. Esta técnica consiste em definir uma faixa de valores para cada hiperparâmetro e utiliza uma métrica de avaliação para maximizar o desempenho da CNN. Neste caso, escolheu-se a acurácia como métrica. O algoritmo Bayesiano testa diferentes combinações de valores de hiperparâmetros e retorna a configuração que obteve o melhor resultado. A configuração final utilizada na CNN está descrita na Tabela 7.

Tabela 7 – Parâmetros utilizados para a configuração da CNN.

Parâmetro	Configuração
Otimizador	Adam
Taxa de aprendizagem	10^{-4}
Número de <i>epochs</i>	50
Tamanho do <i>batch</i>	16
Dropout	50%
Filtro (F_1)	64
D	2
F_2	128
Função de perda	Entropia Cruzada Categórica
Função de Ativação	GELU [105]

A CNN tem como entrada uma imagem, então os sinais de cada um dos blocos

foram transformados em imagens em escala de cinza do tamanho 64×801 para o controle, SSA e ICA (Figura 21). A PCA, devido à variação na quantidade de CPs, gerou imagens de diferentes tamanhos: 47×801 para PCA 99%, 18×801 para PCA 95% e 7×801 para PCA 90%.

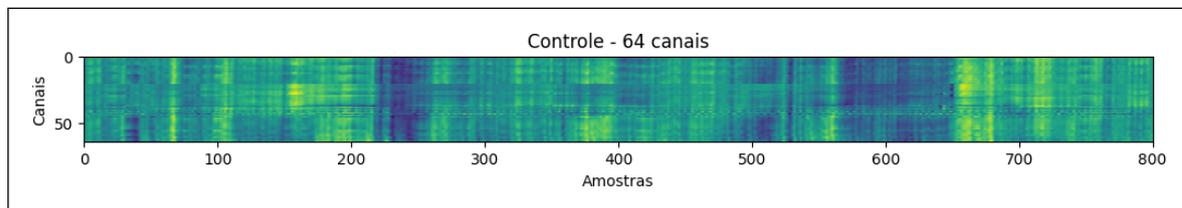


Figura 21 – Imagem referente a uma tarefa contendo 5 s amostrados em 160 Hz. No total, há 64 sensores da EEG e o tamanho da imagem é de 64×801 .

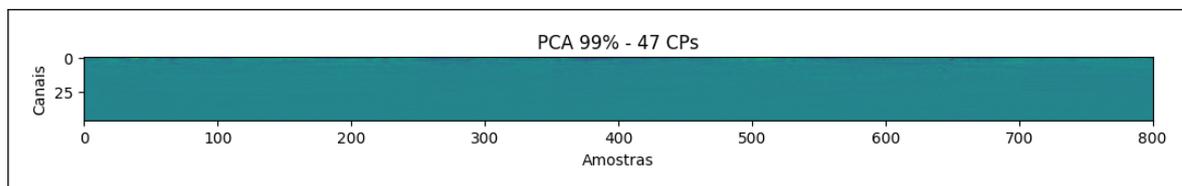


Figura 22 – Imagem após o processamento pela PCA. A razão da cor ser mais uniforme em comparação com a Figura 21 é devido ao fato que a PCA em suas primeiras componentes há uma maior representação da variância do que as demais.

No total, produziram-se 8961 imagens, divididas em três classes: repouso (4326 imagens), IM do punho direito (2298 imagens) e IM do punho esquerdo (2337 imagens). Dividiu-se o banco de dados inicialmente em 80% para treinamento e 20% para teste. Uma subdivisão adicional foi necessária para os dados de treinamento, sendo 80% utilizados para treinamento e 20% para validação.

A acurácia é uma métrica amplamente utilizada para avaliar o desempenho de algoritmos de *machine learning*. Ela é calculada como a proporção entre o número de previsões corretas e o número total de previsões efetuadas pelo algoritmo. Por exemplo, se um modelo classificou corretamente 90 de 100 amostras, sua acurácia seria de 90%. Em termos matemáticos, a acurácia pode ser representada por:

$$Acc = \frac{VP + VN}{N} \quad (3.2)$$

Onde VP e VN representam o número de verdadeiros positivos e verdadeiros negativos, respectivamente, e N representa o número total de previsões.

Entretanto, devido ao desbalanceamento nos dados, é recomendável utilizar outra métrica, como o F1-Score [107]. Ele combina precisão e sensibilidade em uma única pontuação, permitindo avaliar a qualidade do modelo. O cálculo do F1-Score é obtido através da média harmônica entre precisão e sensibilidade, onde o melhor resultado é 1 e o pior é 0. Em termos matemáticos, pode ser representado por:

$$F1 = \frac{2VP}{2VP + FP + FN} \quad (3.3)$$

Onde FP e FN representam o número de falsos positivos e falsos negativos.

Outra métrica utilizada para avaliar o desempenho dos modelos foi o Coeficiente Kappa (Kappa) [108]. Esta métrica é conservadora e compara a proporção de acertos observada (P_o) com a proporção de acertos esperada pelo acaso (P_e) entre dois conjuntos de dados [109]. A Equação 3.4 ilustra como é calculado o Kappa:

$$k = \frac{P_o - P_e}{1 - P_e} \quad (3.4)$$

A métrica Kappa tem valor unitário quando a classificação foi completamente correta e valor zero quando a classificação foi meramente aleatória, sendo o desempenho avaliador de acordo com a Tabela 8.

Tabela 8 – Classificação do coeficiente Kappa

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

Para cada método de processamento, realizou-se o treinamento da CNN por 20 vezes, aumentando assim a precisão estatística dos resultados e permitindo a comparação das médias. Dado o amplo uso na literatura, utilizou-se a Análise de Variância (ANOVA) [110] para avaliar as diferenças entre as médias. Por exemplo, se uma teoria sugere que três tipos diferentes de treinamento terão efeitos diferentes na melhoria da memória, uma ANOVA pode ser utilizada para comparar as médias de melhoria da memória entre os três grupos de treinamento, e as referências teóricas podem ser usadas para interpretar os resultados e verificar se eles suportam ou refutam a teoria.

4 Resultados e Discussão

Neste capítulo, os resultados obtidos com os métodos de processamento estatístico de sinais descritos anteriormente são apresentados. Uma abordagem quantitativa foi adotada, utilizando parâmetros como precisão, coeficiente Kappa, f1-score, tempo de processamento e de treinamento para análise. Esses parâmetros foram selecionados com base em sua relevância para as interfaces cérebro-computador, representando a reprodutibilidade, tempo de resposta adequado e confiabilidade do sistema. A análise desses resultados permitirá uma avaliação abrangente do desempenho dos métodos de processamento estatístico e sua viabilidade para aplicações práticas.

Ao final deste capítulo, os resultados obtidos foram comparados com outros resultados da literatura, permitindo uma contextualização e avaliação em relação a estudos anteriores.

4.1 Análise do Tempo de Processamento e Treinamento

Com base nos dados da Tabela 9, são apresentados os tempos de execução dos algoritmos de processamento estatístico e o tempo de treinamento da CNN. Esses dados são essenciais para avaliar o custo computacional dos métodos utilizados e entender o impacto do processamento estatístico no desempenho geral do sistema.

Tabela 9 – Tempo de utilizado pelos algoritmos de processamento e o tempo decorrido pelo treinamento. Em negrito os melhores tempos de processamento e treinamento.

Algoritmo	Configuração da Variância	Tempo de Processamento (min)		Tempo de Treino (min)	
		Média	DP	Média	DP
Controle	-	-	-	15,30	2,26
ICA	-	19,76	2,52	16,14	2,39
PCA	99%	0,67	0,01	12,60	2,01
	95%	0,68	0,01	7,94	1,09
	90%	0,67	0,01	4,92	0,58
SSA	99%	128,04	16,64	18,52	2,21
	95%	48,36	5,43	18,02	2,11
	90%	35,21	4,35	18,01	2,15

Com base na Tabela 9, iniciou-se a análise em relação à aplicação da ICA, verificou-

se que o tempo médio de processamento foi de 19,76 minutos, com um desvio-padrão de 2,52 minutos. Quanto ao tempo médio de treinamento da CNN, foi de 16,14 minutos, com um desvio-padrão de 2,39 minutos. Ressalta-se que o tempo de processamento mencionado diz respeito exclusivamente ao algoritmo da ICA, não incluindo a análise necessária para identificar artefatos, como os oculares. Em relação ao tempo de treinamento da CNN, não foi observada uma redução significativa em relação ao controle; pelo contrário, houve um acréscimo médio de 0,44 minutos.

No caso da PCA, realizaram-se análises considerando diferentes configurações de variância: 99%, 95% e 90%. Os tempos médios de processamento foram consistentes entre as configurações, apresentando variações mínimas em torno de 0,01 minutos, com desvios-padrão baixos de aproximadamente 0,01 minutos. Observou-se que o tempo médio de processamento do algoritmo da PCA apresentou pouca variação entre as diferentes configurações de variância, o que sugere que a escolha da configuração adequada deve levar em consideração principalmente o tempo de treinamento da CNN.

Ao analisar os tempos médios de treinamento, foi constatado que eles diminuíram à medida que a quantidade de variância retida diminuiu. Para a configuração de 99% de variância, o tempo médio de treinamento foi de 12,60 minutos, com um desvio-padrão de 2,01 minutos. Nas configurações de 95% e 90% de variância, os tempos médios de treinamento foram de 7,94 minutos (desvio-padrão de 1,09 minutos) e 4,92 minutos (desvio-padrão de 0,58 minutos), respectivamente. Essa redução no tempo de treinamento era esperada, uma vez que a quantidade de componentes principais utilizados diminuiu à medida que a quantidade de variância retida é reduzida (47 CPs para 99%, 18 CPs para 95% e 7 CPs para 90%).

É interessante destacar que o tempo de treinamento da configuração PCA 90% foi cerca de três vezes mais rápido do que o controle. Essa redução do tempo de treinamento é relevante, especialmente em aplicações em tempo real, pois leva a um menor tempo de resposta. Assim, a seleção adequada da quantidade de variância retida na PCA pode proporcionar uma redução significativa no tempo de treinamento, tornando o processo mais eficiente e adequado para aplicações em tempo real, onde a resposta rápida é fundamental.

No caso da SSA, também foram realizadas análises para diferentes configurações de variância: 99%, 95% e 90%. Os tempos de processamento foram consideravelmente mais longos em comparação com os outros métodos de processamento. Para a configuração de 99% de variância, o tempo médio de processamento foi de 128,04 minutos, com um desvio-padrão de 16,64 minutos. Para a configuração de 95% de variância, o tempo médio de processamento foi de 48,36 minutos, com um desvio-padrão de 5,43 minutos.

Em relação ao longo tempo de processamento, destaca-se que o algoritmo da SSA expande cada uma das componentes em outras CPs e escolhe as componentes com base na variância. Entretanto, se o banco de dados contém um número grande de componentes,

como no caso deste estudo em que são aproximadamente 8500 amostras e cada uma contendo 64 componentes, isso resulta em uma matriz de trajetória de dimensões elevadas. Essa grande dimensão da matriz de trajetória contribui para um alto custo computacional, tornando inviável o uso da SSA em tempo real ou mesmo em sistemas embarcados que possuem recursos computacionais limitados.

A partir desses resultados, pode-se observar que o grupo de controle apresentou o tempo de treinamento mais elevado, pois a CNN foi treinada apenas com os dados normalizados, sem a aplicação de qualquer algoritmo de processamento adicional. A ICA teve um tempo de processamento razoável, mas ainda mais longo do que o grupo de controle. Por outro lado, a PCA demonstrou tempos de processamento muito baixos para todas as configurações de variância analisadas. Por fim, a SSA apresentou tempos de processamento bastante elevados em comparação com os demais métodos de processamento.

Para uma melhor visão dos resultados da Tabela 9, elaborou-se o gráfico da Figura 23.

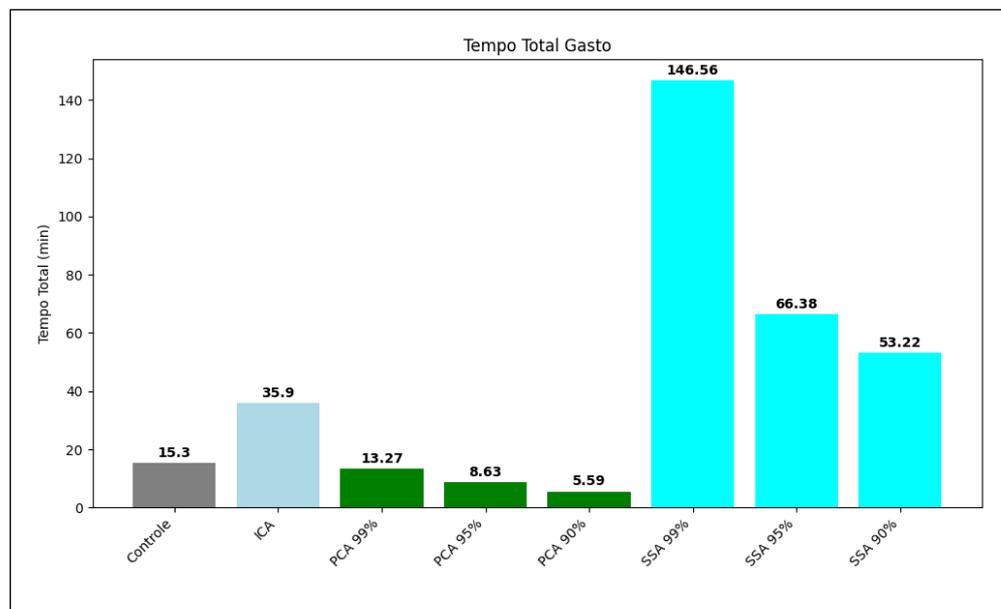


Figura 23 – Gráfico representando o tempo médio total gasto ao somar as técnicas de processamento e a CNN.

A eficiência de tempo dos algoritmos de processamento é de extrema relevância em aplicações que requerem respostas em tempo real, como interfaces cérebro-computador para controle de dispositivos. Em tais casos, é essencial que o tempo de processamento seja minimizado para garantir uma interação fluida e em tempo real com o usuário. Nesse contexto, observa-se na Figura 23 que a PCA se destaca como uma opção promissora, pois apresentou tempos de processamento significativamente menores em comparação com a ICA e a SSA.

No contexto de sistemas embarcados que dependem de baterias, a eficiência ener-

gética é uma preocupação crucial. Métodos de processamento que demandam tempos mais longos podem resultar em um consumo excessivo de energia, reduzindo a vida útil da bateria. Nesse sentido, a PCA se destaca novamente, uma vez que sua eficiência de tempo reduzida também contribui para uma maior eficiência energética.

É importante salientar que os tempos de processamento e treinamento podem variar de acordo com a configuração do sistema utilizado e a quantidade de dados a serem processados. Portanto, é fundamental considerar esses fatores ao selecionar o método de processamento estatístico mais adequado para uma aplicação específica.

No entanto, é crucial ressaltar que a escolha do método de processamento estatístico não deve se basear exclusivamente no tempo de execução e treinamento, mas também nos resultados de desempenho, como precisão e erro absoluto médio. Portanto, é necessário encontrar um equilíbrio entre eficiência de tempo e desempenho adequado para cada aplicação específica.

4.2 Desempenho dos Métodos de Processamento Estatístico

A partir dos experimentos realizados com a CNN, foram obtidos resultados significativos, os quais estão sumarizados na Tabela 10. Essa tabela apresenta as métricas de desempenho alcançadas pela CNN em relação às classes de IM. Esses resultados são relevantes para avaliar a eficácia do modelo proposto e compará-lo com outros métodos existentes no contexto deste estudo.

Tabela 10 – Resultados da classificação utilizando diferentes métodos de processamento estatístico de sinais em combinação com uma CNN.

Algoritmo	Configuração da Variância	Acurácia		Kappa		F1 - Score	
		Média	DP	Média	DP	Média	DP
Controle	-	0,777	0,008	0,647	0,012	0,761	0,001
ICA	-	0,714	0,011	0,545	0,018	0,013	0,013
PCA	99%	0,783	0,007	0,654	0,009	0,765	0,007
	95%	0,782	0,007	0,654	0,010	0,765	0,008
	90%	0,762	0,008	0,624	0,012	0,746	0,009
SSA	99%	0,747	0,008	0,599	0,012	0,730	0,008
	95%	0,702	0,007	0,526	0,009	0,680	0,006
	90%	0,688	0,008	0,504	0,008	0,665	0,007

Analisando os resultados da Tabela 10, em relação a PCA, pode-se observar os resultados de desempenho da classificação utilizando diferentes configurações de variância

para a PCA.

A acurácia média para a PCA variou entre 0,762 e 0,783 para as três configurações de variância. Esses valores indicam que o desempenho da PCA foi consistente em relação à acurácia, não apresentando grandes variações nos diferentes níveis de variância considerados.

No que diz respeito ao Coeficiente Kappa, que é uma métrica que considera o desempenho além da concordância aleatória, os valores médios variaram entre 0,624 e 0,654. Considerando a Tabela 8, todos os valores se encontram na faixa de “bom” desempenho, indicando uma concordância significativa além do esperado por acaso.

O F1-score é especialmente útil quando as classes estão desbalanceadas, que foi caso desse trabalho. Então analisando a PCA, que variou entre 0,746 e 0,765. Esses valores indicam um desempenho satisfatório da PCA em relação à classificação das classes de IM.

Ao comparar os resultados da PCA com o controle, pode-se observar que a PCA obteve um desempenho ligeiramente superior tanto em termos de acurácia, coeficiente Kappa e F1-score. Isso sugere que a PCA foi capaz de capturar informações relevantes dos sinais de IM e melhorar o desempenho da classificação em comparação com o uso apenas da CNN.

Em relação à ICA, observou-se uma diminuição significativa no desempenho da classificação de sinais de IM. A acurácia média obtida pela ICA foi de 0,714, com um desvio padrão de 0,011, demonstrando um desempenho inferior em comparação com o controle e a PCA. Esses resultados sugerem que a extração de características realizada pela ICA pode ter introduzido ruído ou reduzido a quantidade de informações relevantes para a classificação das imagens de IM.

Ao analisar o coeficiente Kappa, constatou-se que os valores médios obtidos pela ICA foi de 0,545. Esse valor corresponde a uma classificação de desempenho “regular” de acordo com a tabela de classificação do coeficiente Kappa. Tal redução na concordância além do esperado por acaso indica que a extração de características da ICA afetou negativamente a capacidade da CNN em realizar a classificação correta das classes de IM.

Em relação ao F1-score, o valor médio obtido pela ICA foi de 0,013, indicando um desempenho muito baixo em termos de equilíbrio entre precisão e *recall*. Esses resultados sugerem que a extração de características realizada pela ICA não foi eficaz na captura das informações discriminativas presentes nos sinais de IM.

Comparando os resultados da ICA com o controle e a PCA, evidencia-se que a extração de características realizada pela ICA teve um impacto negativo no desempenho da CNN. Os resultados de desempenho, medidos pelo coeficiente Kappa e F1-score, indicam uma redução na capacidade da CNN em classificar corretamente os sinais de IM após a aplicação da ICA. Esses achados corroboram com observações anteriores, como no

estudo de Sleight et al. [111], que também observaram uma queda de 8,2% na acurácia na classificação de sinais da EEG-IM utilizando o método SVM (*Support Vector Machine*) após a aplicação da ICA.

Destaca-se que o fator humano na escolha das componentes a serem removidas pode ter influenciado nos resultados obtidos. Apesar de todos os cuidados tomados no processo de seleção das componentes independentes, é possível que algumas componentes relacionadas à atividade cerebral de IM tenham sido inadvertidamente escolhidas, potencialmente afetando a inferência da CNN.

Em relação a SSA, seu desempenho foi inferior aos métodos anteriores. A acurácia média variou entre 0,688 e 0,747, com um desvio padrão de 0,008. Comparado aos resultados do controle, PCA e ICA, o SSA apresentou um desempenho geralmente mais baixo. Isso sugere que o SSA pode não ter sido capaz de extrair as informações relevantes dos sinais de IM de forma eficaz.

Ao analisar o coeficiente Kappa, observa-se valores médios entre 0,504 e 0,599. Esses valores estão na faixa de “regular” desempenho de acordo com a Tabela 8. Isso indica que o SSA teve um desempenho abaixo do esperado em termos de concordância além do acaso, novamente evidenciando a dificuldade em extrair informações discriminativas dos sinais utilizando essa técnica.

O F1-score médio variou entre 0,665 e 0,730, indicando um desempenho abaixo do esperado em termos de equilíbrio entre precisão e *recall*. Esses resultados sugerem que o SSA não foi capaz de capturar adequadamente as informações necessárias para uma classificação precisa das classes de IM.

Um possível motivo para o baixo desempenho do SSA pode ser a inadequação da técnica em lidar com as características específicas dos sinais de IM. O SSA é baseado na decomposição do sinal em componentes de baixa frequência, média frequência e alta frequência, e a classificação pode ser prejudicada se as informações discriminativas estiverem presentes em componentes de frequência que não são adequadamente representados pela SSA.

4.2.1 Teste ANOVA

Ao realizar o teste de hipótese ANOVA de um fator para comparar estatisticamente as médias da acurácia entre o controle e os dois melhores modelos da PCA, formularam-se as seguintes hipóteses:

$$H_0 : \mu_{controle} = \mu_{PCA\ 99\%} = \mu_{PCA\ 95\%}$$

$$H_1 : \mu_{controle} \neq \mu_{PCA\ 99\%} \neq \mu_{PCA\ 95\%}$$

Considerando um nível de significância de 0,05, o valor-P obtido foi igual a 0,03. Dado que o valor-P é menor que o nível de significância, há evidências estatísticas suficientes para rejeitar H_0 . Isso indica que há diferença estatisticamente significativa entre as médias de acurácia do controle e dos modelos da PCA com diferentes níveis de variância. No anexo A encontram-se outros valores obtidos pelo teste ANOVA.

Essa análise estatística confirma a eficiência da PCA em preservar as informações relevantes no sinal de IM após o redimensionamento. Os resultados obtidos pela PCA com diferentes níveis de variância apresentaram diferenças estatisticamente significativas em relação ao controle. Esses resultados sugerem que a redução da dimensionalidade dos sinais não comprometeu a capacidade de classificação da CNN, e que houve um ganho médio de 0,005 em relação ao controle (PCA 99%).

Essa observação é consistente com a teoria subjacente à PCA, que busca maximizar a variância dos dados em direção as principais componentes. Ao preservar a maior parte da variância dos sinais, a PCA garante a retenção das informações discriminativas relevantes para a classificação. Portanto, mesmo com uma redução na dimensionalidade, os modelos da PCA conseguiram manter um desempenho semelhante ao do controle, destacando sua eficiência no processamento de sinais para classificação de IM.

Esses resultados são promissores para aplicações práticas, pois a redução da dimensionalidade dos sinais por meio da PCA pode levar a uma menor carga computacional e a uma maior eficiência em termos de tempo de processamento e treinamento da CNN. Além disso, a capacidade da PCA de preservar informações relevantes nos sinais pode contribuir para a generalização e robustez dos modelos em cenários de aplicação do mundo real.

Portanto, com base na análise estatística e nas fundamentações teóricas da PCA, é possível afirmar que essa técnica de processamento de sinais apresenta resultados promissores e pode ser uma escolha adequada para a classificação de sinais de IM em aplicações práticas. No entanto, pesquisas futuras podem explorar a otimização dos parâmetros da PCA e avaliar seu desempenho em conjuntos de dados mais extensos e diversificados para uma validação mais abrangente de sua eficácia.

4.2.2 Comparação com a Literatura

Nesta seção, apresenta-se uma tabela contendo um compilado de resultados em relação à métrica acurácia. Para isso, selecionaram-se os trabalhos que empregam alguma técnica de *machine learning* e que a quantidade de voluntários utilizados no trabalho fosse no mínimo de nove voluntários. Dessa forma, elaborou-se a Tabela 11, a qual foi utilizada como ferramenta de comparação entre os resultados alcançados neste estudo e aqueles encontrados na literatura. Através dessa comparação, foi possível avaliar o desempenho

do modelo proposto em relação aos métodos e abordagens previamente relatados.

Tabela 11 – Resultados encontrados na literatura. Células com “ - ” indicam que a informação não está disponível no trabalho.

Referências	Amostras	Frequência Utilizada	Processamento de sinal	Deep Learning Utilizado	Acurácia
[112]	14 volun.	0-125 Hz	-	CNN	88,9%
[113]	9 volun.	8-35 Hz	-	DBN	83,0%
[114]	9 volun.	5-30 Hz	SVD	DBN	80,4%
[115]	9 volun.	8-35 Hz	-	RNN-LSTM	79,6%
	109 volun.	0,5-40 Hz	PCA - 99%	CNN	78,3%
	109 volun.	0,5-40 Hz	PCA - 95%	CNN	78,2%
[116]	12 volun.	0,5-100 Hz	-	DBN	78,0%
	109 volun.	0,5-40 Hz	Controle	CNN	77,7%
[117]	9 volun.	8-30 Hz	-	RNN-GRU	77,0%
	109 volun.	0,5-40 Hz	PCA - 90%	CNN	76,2%
[118]	9 volun.	6-30 Hz	-	CNN	75,1%
[119]	9 volun.	8-30 Hz	CSP	MLPNN	75,0%
	109 volun.	0,5-40 Hz	SSA - 99%	CNN	74,7%
[120]	9 volun.	4-40 Hz	-	CNN	74,0%
	109 volun.	0,5-40 Hz	ICA	CNN	71,4%
[121]	9 volun.	8-35 Hz	-	DBN	71,0%
[122]	109 volun.	0,5-30 Hz	-	RNN-LSTM	70,6%
[123]	9 volun.	4-40 Hz	-	CNN	70,6%
	109 volun.	0,5-40 Hz	SSA - 95%	CNN	70,2%
[124]	109 volun.	-	-	CNN	69,8%
	109 volun.	0,5-40 Hz	SSA - 90%	CNN	68,8%
[125]	12 volun.	-	-	RNN-LSTM	68,0%
[126]	9 volun.	8-30 Hz	-	MLPNN	67,8%
[112]	9 volun.	0-38 Hz	CSP	CNN	67,7%
[118]	9 volun.	8-30 Hz	-	CNN	61,0%

Ao considerar os estudos que empregaram o mesmo conjunto de dados composto por 109 voluntários, os resultados obtidos neste trabalho apresentaram um desempenho satisfatório, conforme evidenciado pela análise da Tabela 11. Em comparação com a referência [124], observou-se uma melhora de 8,5% na taxa de acurácia, enquanto em relação à referência [122], a melhora foi de 7,7%. No entanto, é pertinente ressaltar que a referência [124] não forneceu informações detalhadas sobre os métodos de processamento do sinal ou as faixas de frequência utilizadas, o que limita a compreensão completa e a comparação direta dos resultados obtidos neste estudo com os resultados relatados nessa referência.

Ao examinar os resultados alcançados pela referência [112], que obteve o melhor desempenho geral na classificação, observa-se que foram utilizados dois conjuntos de dados distintos. O primeiro conjunto de dados é de acesso público, baseado na BCI Competition 2a [92], enquanto o segundo conjunto foi elaborado pelos autores do artigo e disponibi-

lizado posteriormente à sua publicação. Cabe destacar que, na mesma referência, foram obtidos dois resultados diferentes para a mesma arquitetura de rede neural convolucional, indicando que a qualidade da aquisição dos dados influencia diretamente os resultados alcançados pela rede neural convolucional.

É relevante enfatizar que alguns estudos da literatura não apresentaram detalhes sobre os métodos de processamento de sinal ou as faixas de frequência utilizadas, dificultando a comparação direta com os resultados obtidos neste estudo.

Outro aspecto de relevância a ser considerado é o uso predominante do banco de dados da BCI Competition 2a, disponível na referência [92], que possui um número limitado de voluntários. Essa limitação pode afetar a capacidade de generalização do classificador, uma vez que conjuntos de dados maiores e mais diversificados tendem a proporcionar resultados mais confiáveis. Portanto, sugere-se que pesquisas futuras sejam direcionadas para a coleta de conjuntos de dados mais extensos e abrangentes, a fim de aprimorar a confiabilidade e a aplicabilidade dos modelos de classificação.

Em síntese, os resultados obtidos neste estudo fornecem evidências que corroboram a eficácia da abordagem proposta, que combina um conjunto de dados abrangente com a técnica da PCA com 99% de variância explicada, na tarefa de classificação de sinais por meio de *deep learning*. No entanto, é crucial considerar as limitações e desafios encontrados ao longo do estudo, como a falta de detalhamento nos estudos da literatura e a restrição do tamanho dos conjuntos de dados disponíveis. Essas considerações fornecem uma base sólida para orientar pesquisas futuras e aprimorar ainda mais os resultados alcançados nessa área de estudo.

5 CONCLUSÕES

A classificação de sinais da EEG-IM com eficiência é um desafio significativo devido à baixa relação sinal-ruído e à variabilidade entre os indivíduos. Este estudo abordou a aplicação de diferentes técnicas de processamento de sinais, como PCA, ICA e SSA, em conjunto com uma CNN, visando melhorar a classificação dos sinais de IM.

A aplicação da PCA permitiu a redução na quantidade de componentes dos sinais de IM, resultando em imagens menores e uma CNN mais rápida. Isso contribuiu para um menor custo computacional e um tempo de treinamento reduzido. Os resultados obtidos indicaram que a PCA em combinação com a CNN apresentou um desempenho superior em relação ao controle, proporcionando uma melhoria estatisticamente significativa sem aumentar o custo computacional. A PCA reduziu o tempo de treinamento em até 63,5%, o que é uma vantagem considerável para aplicações que exigem velocidade no processamento, como em sistemas de classificação da EEG em tempo real ou em BCIs assistivas com base IM.

Por outro lado, a ICA e o SSA apresentaram resultados inferiores. A ICA teve um desempenho comprometido devido à remoção de artefatos, o que resultou na perda de informações de IM devido à baixa relação sinal-ruído. A SSA mostrou desempenho baixo em todas as métricas avaliadas, além de demandar um alto custo computacional. A remoção de ruído na SSA pode ter levado à perda de informações relevantes, prejudicando o desempenho da CNN.

5.1 Resumo das Contribuições

Este estudo representa e fornece contribuições para o campo de processamento de sinais EEG e sistemas BCI baseados em imaginação motora que empregam técnicas de *machine learning* como classificador:

- Destacou-se o potencial da PCA para sistemas BCI-IM que buscam classificação em tempo real. A PCA se mostrou capaz de reduzir significativamente o tempo de processamento da rede neural sem afetar negativamente a acurácia da classificação. Além disso, a técnica foi eficaz na extração de características relevantes e filtragem de ruídos dos sinais EEG, melhorando o desempenho da classificação pela rede neural em comparação ao controle.
- Evidenciou-se que o uso da ICA para remoção de artefatos em EEG ainda apresenta limitações para sua aplicação. Isso ocorre porque a ICA requer a classi-

ficação manual das componentes independentes antes da eliminação dos artefactos, demandando intervenção humana. Essa intervenção pode impactar negativamente o desempenho do *machine learning*, tornando essa abordagem menos viável para sistemas que exigem resposta rápida e automatizada.

- Demonstrou-se que a SSA requer alto custo computacional para processar os sinais EEG, tornando inviável seu uso em conjunto com técnicas de *machine learning* para classificação de sinais EEG de imaginação motora. Essa limitação torna a SSA menos adequada para aplicações que exigem baixo consumo de recursos computacionais e alta eficiência no processamento.
- Forneceram-se *insights* sobre a seleção adequada de técnicas de processamento de sinais EEG ao almejar classificação com *machine learning*, ressaltando as trocas entre velocidade de processamento e desempenho. Essas informações são valiosas para orientar a escolha das técnicas mais apropriadas de acordo com as necessidades específicas de cada aplicação.

Essas contribuições refletem o impacto deste estudo no campo de pesquisa e sua relevância para o desenvolvimento de sistemas de classificação de IM mais eficientes e aplicáveis em cenários práticos. As descobertas apresentadas neste trabalho contribuem com o progresso e a aplicabilidade das técnicas de processamento de sinais e *machine learning* em aplicações biomédicas e de saúde, podendo impactar positivamente a qualidade de vida de muitas pessoas.

5.2 Sugestão para Trabalhos Futuros

Com base nos resultados obtidos e nas análises realizadas, há oportunidades para trabalhos futuros nessa área de pesquisa. Alguns possíveis direcionamentos são:

1. Explorar outras técnicas de processamento de sinais: Além da PCA, a ICA e o SSA foram avaliados neste estudo. No entanto, existem outras técnicas de processamento de sinais que podem ser investigadas, como a transformada wavelet, o filtro de Kalman, entre outros. Essas técnicas podem ser aplicadas em conjunto com a CNN para avaliar seu impacto no desempenho da classificação de sinais de IM.
2. Investigar abordagens híbridas: Uma abordagem promissora é combinar diferentes técnicas de processamento de sinais em um modelo híbrido. Por exemplo, é possível explorar a combinação da PCA e ICA para capturar informações complementares dos sinais. Essa abordagem pode levar a melhorias no desempenho da classificação, aproveitando as vantagens de cada técnica.

3. Em relação a ICA, desenvolver algoritmos eficientes para classificação de artefatos automaticamente, o que eliminaria a intervenção humana.
4. Ampliar o conjunto de dados: O presente estudo utilizou um conjunto de dados de 109 voluntários. No entanto, é recomendado expandir o conjunto de dados para avaliar a generalização e robustez dos modelos desenvolvidos. O aumento do tamanho do conjunto de dados pode fornecer resultados mais confiáveis e representativos, permitindo conclusões mais robustas.
5. Investigar a otimização dos parâmetros: A otimização dos parâmetros dos modelos é uma etapa importante para melhorar o desempenho da classificação. Seria interessante explorar técnicas de otimização, como a busca em grade ou algoritmos genéticos, para encontrar os melhores parâmetros para os modelos de processamento de sinais e CNN.

Essas são apenas algumas sugestões de possíveis trabalhos futuros. A área de processamento de sinais e *machine learning* oferece uma ampla gama de oportunidades de pesquisa e desenvolvimento.

Apêndices

APÊNDICE A – Formulação

A.1 Formulação da SSA

O algoritmo da SSA é composto por dois estágios complementares: decomposição e reconstrução. Esses estágios são descritos detalhadamente nas seções a seguir.

A.1.1 Decomposição

Neste estágio, a série inicial é decomposta em uma soma de subséries, cada uma representando um componente que a constitui.

Então, considere uma série temporal de valores reais, onde $N > 2$:

$$F = (f_0, \dots, f_{i-1}), \quad 0 \leq i \leq N \quad (\text{A.1})$$

Sendo F uma série temporal e N o tamanho temporal da série. Então, defini-se um vetor com L -laggs:

$$X_j = (f_{j-1}, \dots, f_{j+L-2})^T, \quad 1 \leq j \leq K \quad (\text{A.2})$$

Onde L é o tamanho da janela, que deve está contida no intervalo $2 \leq L \leq \frac{N}{2}$ segundo a referência [99]. O valor de K é tal que se inclua todos os valores da série, então $K = N - L + 1$. Expandindo a Equação A.2 em seus primeiros termos:

$$\begin{aligned} X_1 &= (f_0, f_1, f_3, \dots, f_{K-1})^T \\ X_2 &= (f_1, f_2, f_3, \dots, f_K)^T \\ X_3 &= (f_2, f_3, f_4, \dots, f_{K+1})^T \\ &\vdots \\ X_{N-L} &= (f_{N-L}, f_L, f_{L+1}, \dots, f_{N-1})^T \end{aligned}$$

Rescrevendo em forma vetorial:

$$\mathbf{X} = \begin{pmatrix} f_0 & f_1 & \cdots & f_{K-1} \\ f_1 & f_2 & \cdots & f_K \\ \vdots & \vdots & \ddots & \vdots \\ f_{L-1} & f_L & \cdots & f_{N-1} \end{pmatrix} \quad (\text{A.3})$$

A Equação A.3 é a matriz trajetória da série F e também uma *Matriz de Hankel* [69]. Observa-se que há defasagem em suas colunas determina pelo tamanho do L.

Próximo passo consiste na decomposição em valores singulares (SVD, de *Singular Value Decomposition*), a matriz da Equação A.3 será reescrita como uma soma de matrizes elementares. Para isso, seja $\mathbf{S} = \mathbf{X}\mathbf{X}^T$. Denote por $\lambda_1, \dots, \lambda_L$ os autovalores de S tomados em ordem decrescente de magnitude ($\lambda_1 \geq \dots \geq \lambda_L \geq 0$) e por U_1, \dots, U_L o sistema ortonormal dos autovetores da matriz S correspondentes a esses autovalores. Seja $d = \max\{i : \lambda_i > 0\}$, onde d é o posto de S, que é o número de autovalores diferentes de zero da matriz S.

Se $V_i = \mathbf{X}^T U_i / \sqrt{\lambda_i}$ ($i = 1, \dots, d$), então a SVD da matriz de trajetória X pode ser escrita como:

$$X = X_1 + \dots + X_d \quad (\text{A.4})$$

Onde $X_i = \sqrt{\lambda_i} U_i V_i^T$. As matrizes X_i possuem ranque 1, portanto são matrizes elementares. O conjunto $(\sqrt{\lambda_i}, U_i, V_i)$ é conhecida como a *i-ésimo autotriplo* de autovalores da Equação A.4.

Os autovetores esquerdos U_i e os componentes principais V_i também possuem uma estrutura temporal, o que os torna séries temporais [127].

A.1.2 Reconstrução

Neste estágio, são criados componentes que representam grupos de matrizes mais semelhantes, que serão utilizados para reconstruir a série temporal original após a remoção do ruído. Essa etapa tem como objetivo identificar padrões ou estruturas significativas nos dados, agrupando matrizes que compartilham características semelhantes.

Após a decomposição da série em componentes, é possível selecionar os componentes mais relevantes, com base na variância explicada ou em critérios específicos. Em seguida, esses componentes selecionados são utilizados para reconstruir a série original, eliminando o ruído ou as informações irrelevantes.

A reconstrução da série é importante, pois permite obter uma representação mais clara dos padrões e tendências presentes nos dados originais, ao mesmo tempo em que

reduz o impacto do ruído ou de outras variações indesejadas. A qualidade da reconstrução depende da capacidade do algoritmo em identificar e agrupar as matrizes relevantes durante o estágio de decomposição.

Após obter os conjuntos de autotriplos, é realizado o particionamento do conjunto de índices i, \dots, d em m componentes principais. Nessa etapa, selecionamos os primeiros m autotriplos associados aos componentes interpretáveis da série e excluimos os remanescentes ($d-m$) que estão relacionados ao ruído.

Formalmente, definimos o conjunto $I = 1, \dots, m$ para representar os índices dos autotriplos selecionados como componentes principais, e o conjunto $I^c = m + 1, \dots, d$ para representar os índices dos autotriplos remanescentes associados ao ruído.

O objetivo dessa seleção adequada do conjunto I é reescrever a matriz de trajetória como:

$$\mathbf{X} = \sum_{i \in I} \lambda_i U_i V_i^T + \epsilon \quad (\text{A.5})$$

Em que ϵ denota o ruído e os termos restantes representam o sinal. Nesse contexto, o procedimento de escolha dos m componentes principais é chamado de grupo de autotriplos.

Neste estágio, cada matriz X_i é transformada em uma série temporal e considerada como um componente aditivo da série inicial X_t [100]. Embora teoricamente todos os componentes da série sejam separáveis, na prática, nem todas as matrizes resultantes da SVD são matrizes de Hankel.

Portanto, é necessário realizar uma transformação da matriz arbitrária em uma matriz de Hankel e, subsequentemente, em uma matriz de trajetórias e, finalmente, em uma série temporal. O procedimento de hankealização de uma matriz arbitrária $X_{L \times K}$ é realizado da seguinte maneira: seja $A_s = \{(l, k) : l + k = s, 1 \leq l \leq L, 1 \leq k \leq K\}$ e $i + j = s$, o elemento \tilde{x}_{ij} da matriz hankealizada \tilde{X} é calculado como:

$$\tilde{x}_{ij} = \frac{1}{|A_s|} \sum_{(l,k) \in A_s} x_{lk}, \quad (\text{A.6})$$

onde $|A_s|$ é o número de elementos no conjunto A_s .

Por fim, cada matriz X_i é transformada em uma nova série de tamanho N . Aplicando o procedimento de *hankealização* a todos os componentes da matriz X , obtemos a expressão:

$$\tilde{X} = \tilde{X}_1 + \dots + \tilde{X}_m \quad (\text{A.7})$$

A *hanquealização* é considerada um procedimento ótimo, uma vez que a matriz *hanquealizada* \tilde{X} é considerada uma boa aproximação de X , e, portanto, uma boa aproximação da série temporal original.

Anexos

ANEXO A – Componentes da ICA

A.1 Componentes

Nesta seção apresentadas-se as componentes obtidas por meio da técnica de ICA. As Figuras 24, 25 e 26 mostram as componentes em ordem.

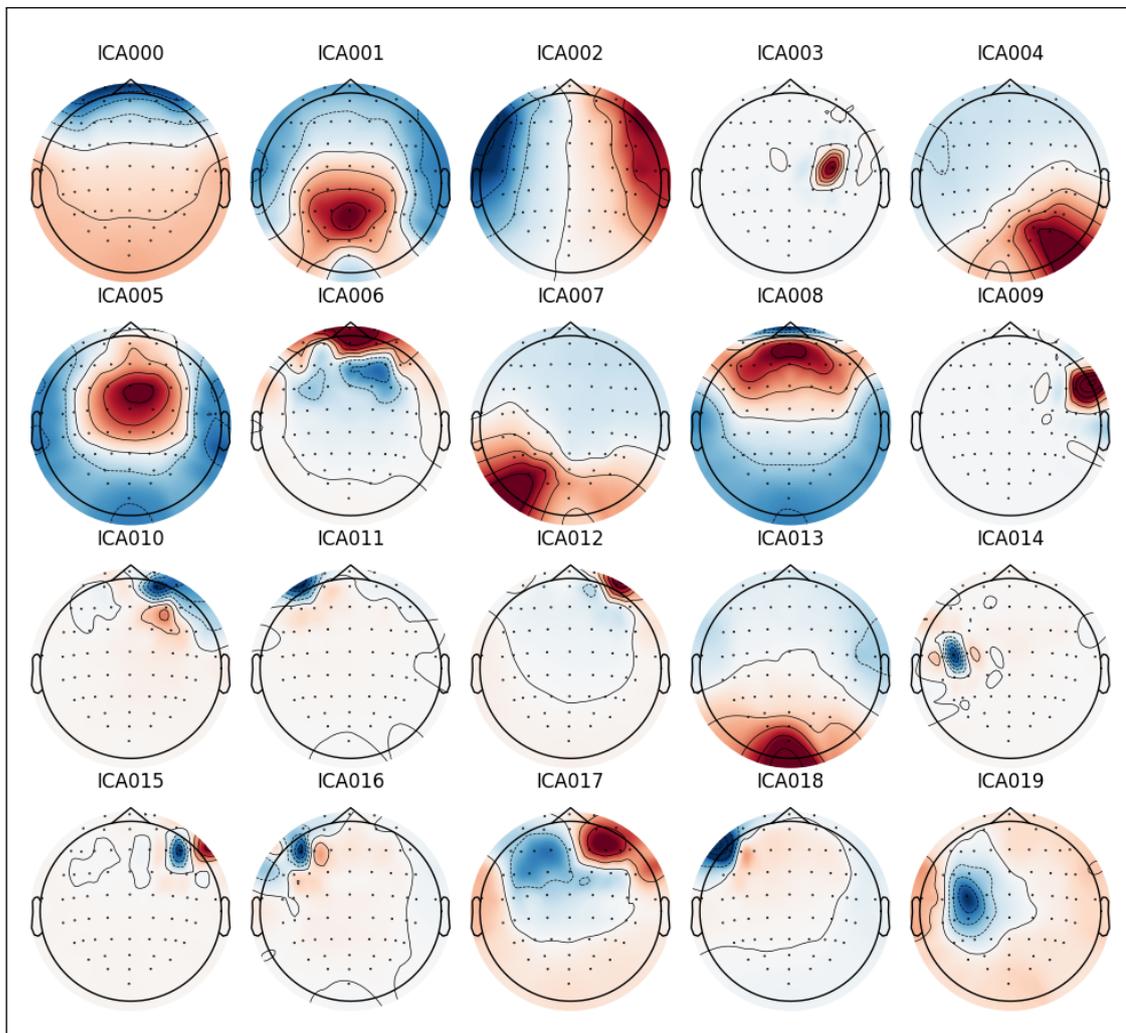


Figura 24 – Componentes em ordem - parte 1.

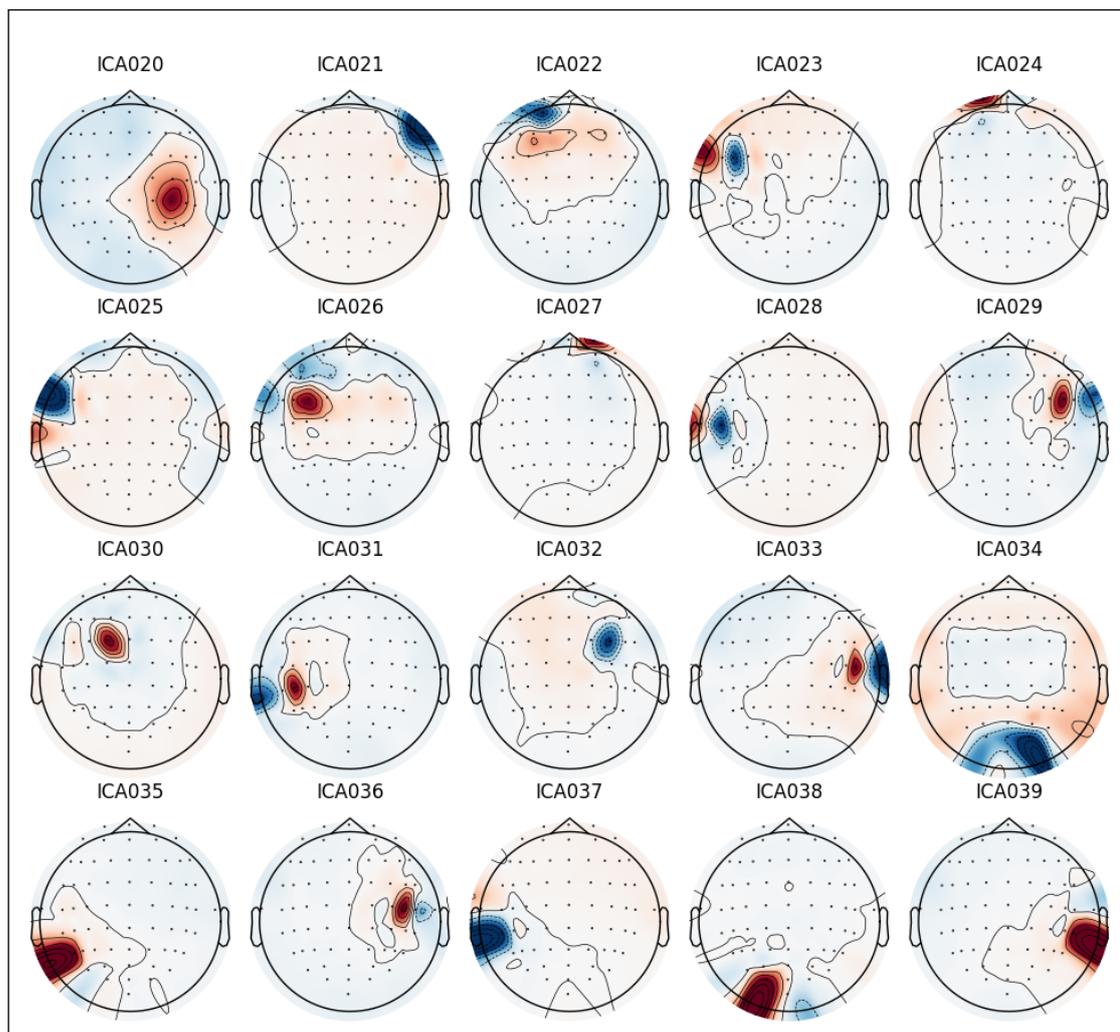


Figura 25 – Componentes em ordem - parte 2.

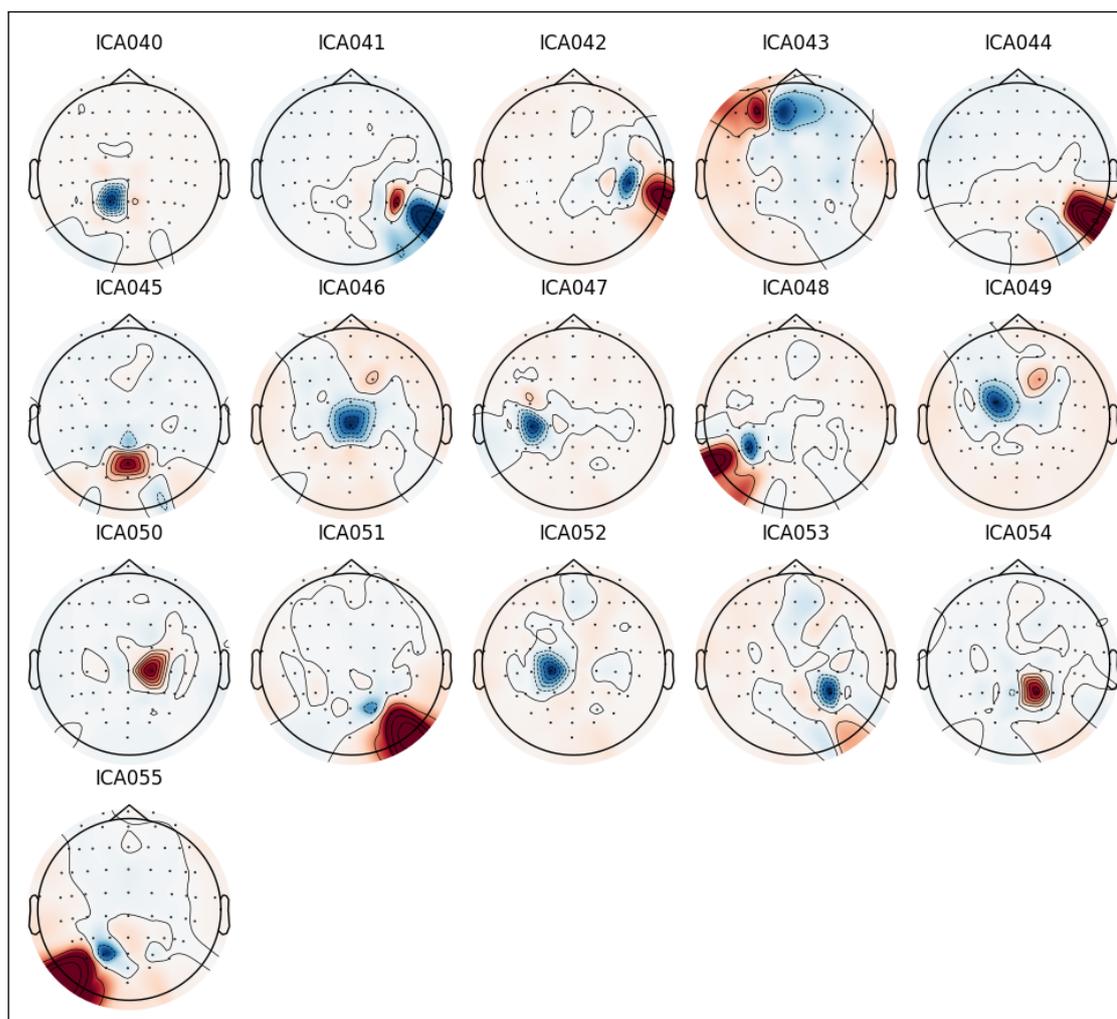


Figura 26 – Componentes em ordem - parte 3.

A.2 Exemplos de Artefatos

Esta seção apresenta-se a análise das componentes obtidas por meio da técnica da ICA. As Figuras 27, 28, 29 e 30 ilustram diferentes componentes identificadas durante o processamento dos sinais de EEG, para classificação utilizou-se a referência [95] como base.

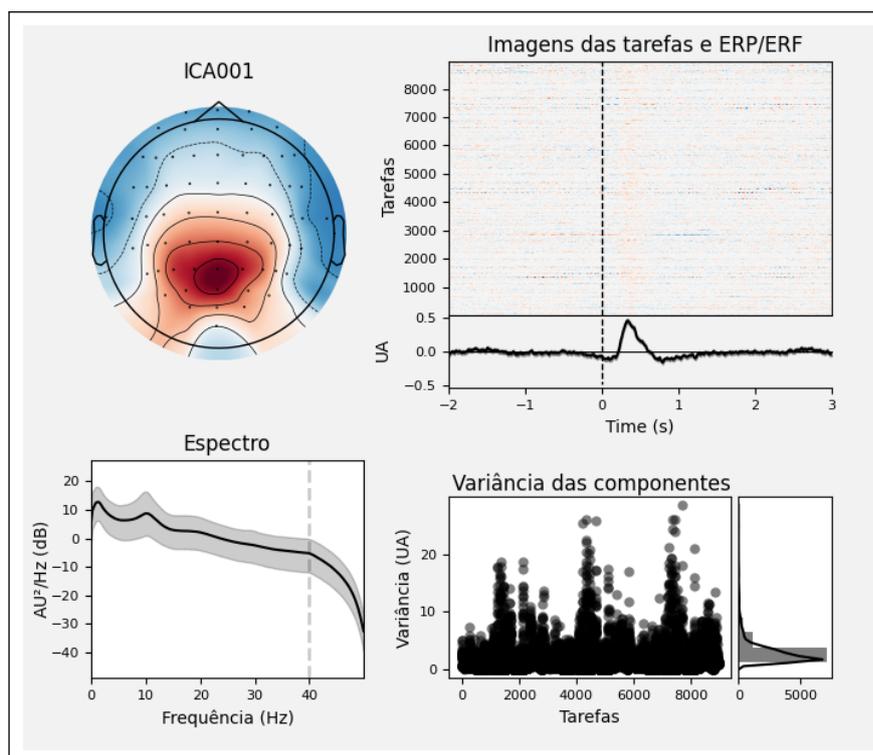


Figura 27 – Análise da componente ICA001 revela uma polarização nos sensores da região do Lobo Parietal, indicando atividade cerebral.

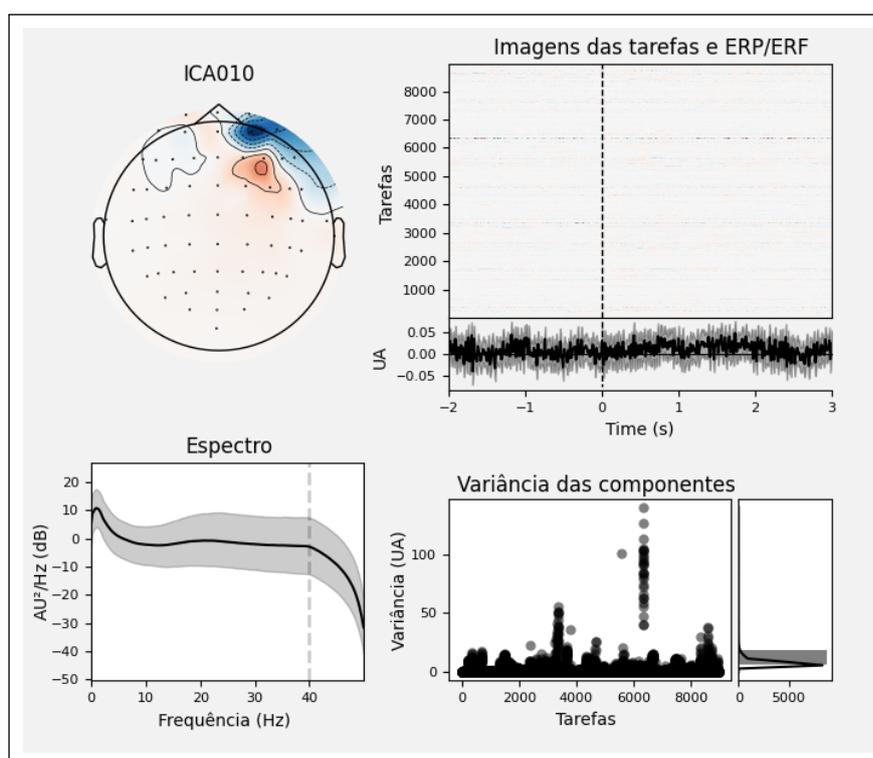


Figura 28 – Polarização observada no olho esquerdo na componente, indicando movimento muscular, como o fechamento do olho direito.

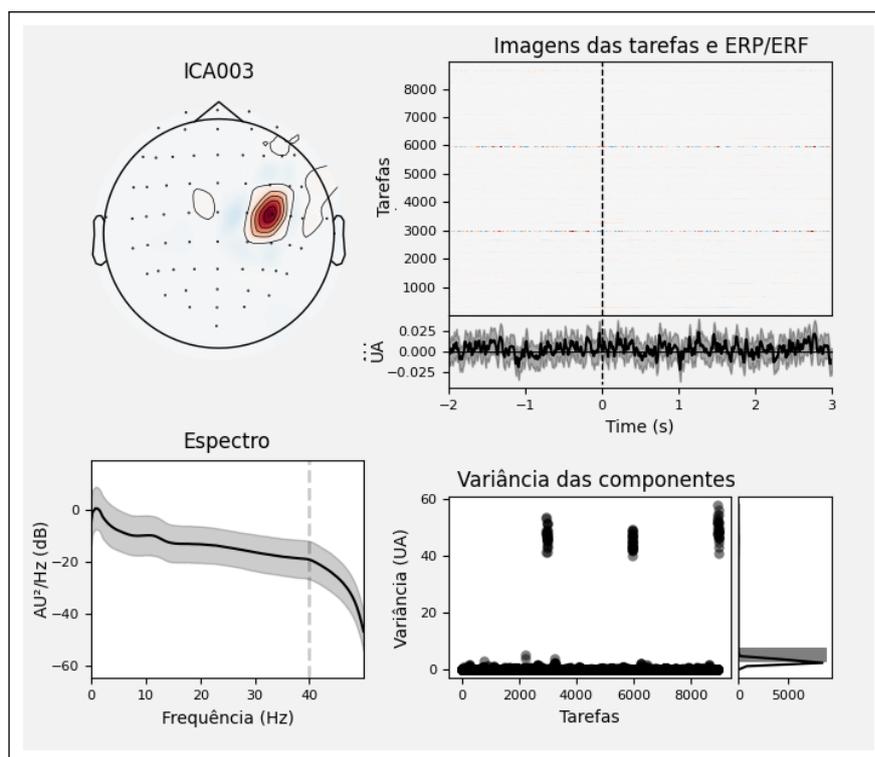


Figura 29 – Polarização específica em um dos sensores na componente ICA003, indicando ruído no sensor.

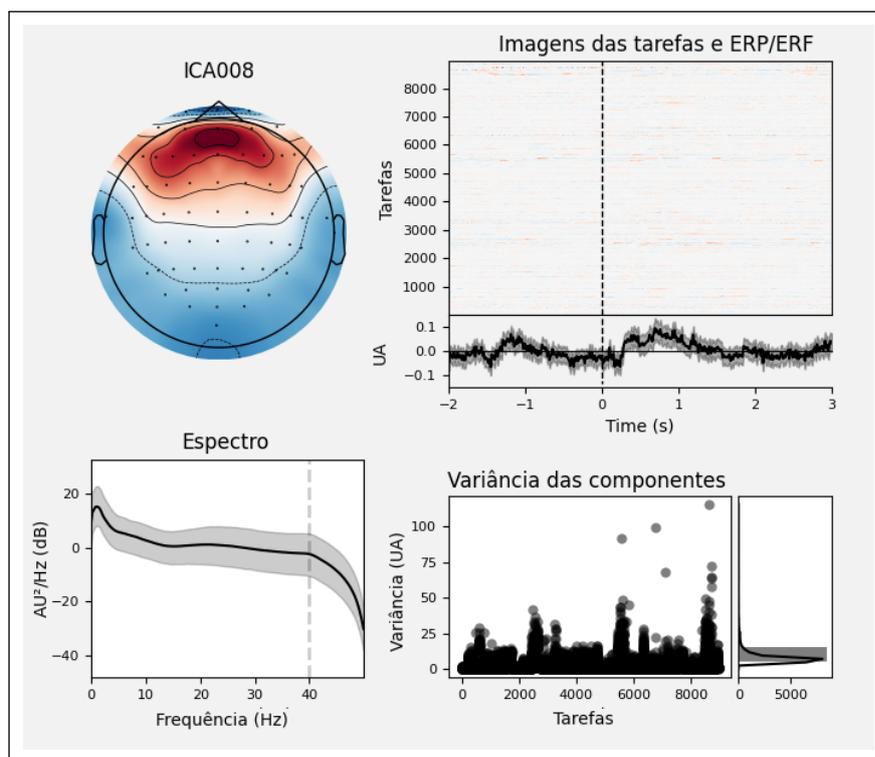


Figura 30 – Componente classificada como "outros", considerada um sinal cerebral sem uma origem específica no cérebro.

Referências

- 1 WOLPAW, J. R. et al. Brain–computer interfaces for communication and control. *Clinical Neurophysiology*, Elsevier, v. 113, n. 6, p. 767–791, 2002. 15
- 2 PFURTSCHELLER, G. et al. "thought- control of functional electrical stimulation to restore hand grasp in a patient with tetraplegia. *Neuroscience Letters*, v. 351, p. 33–36, Jul 2003. ISSN 0304-3940. 15
- 3 CHAUDHARY U., B.-N.; RAMOS-MURGUIALDAY, A. Brain–computer interfaces for communication and rehabilitation. *Nature Reviews Neurology*, Nature Publishing Group, v. 12, n. 9, p. 513–525, 2016. 15
- 4 WIDGE, A. S.; DOUGHERTY, D. D.; MORITZ, C. T. Affective brain-computer interfaces as enabling technology for responsive psychiatric stimulation. *Brain-Computer Interfaces*, Taylor Francis, v. 1, n. 2, p. 126–136, 2014. 15
- 5 MIRANDA, R. A.; LEEB, A. R.; PFURTSCHELLER, G. Darpa-funded efforts in the development of novel brain–computer interface technologies. *Journal of Neuroscience Methods*, v. 244, p. 52–67, Apr 2015. ISSN 0165-0270. 15
- 6 CHUANG, C.-H. et al. Driver’s cognitive state classification toward brain computer interface via using a generalized and supervised technology. In: IEEE. *The 2010 International Joint Conference on Neural Networks (IJCNN)*. [S.l.], 2010. p. 1–7. 15
- 7 BOS, D. e. a. P.-O. Brain-computer interfacing and games. In: _____. [S.l.: s.n.], 2010. p. 149–178. 15
- 8 KOUSHIK, A.; AMORES, J.; MAES, P. Real-time sleep staging using deep learning on a smartphone for a wearable eeg. *arXiv preprint arXiv:1811.10111*, 2018. 15
- 9 LOTTE, F.; BOUGRAIN, L.; CLERC, M. Electroencephalography (eeg)-based brain-computer interfaces. In: _____. *Wiley Encyclopedia of Electrical and Electronics Engineering*. Hoboken, NJ, USA: John Wiley Sons, Inc., 2015. p. 1–20. 16
- 10 PFURTSCHELLER, G.; SILVA, F. H. Lopes da. Event-related eeg/meg synchronization and desynchronization: basic principles. *Clinical neurophysiology: official journal of the International Federation of Clinical Neurophysiology*, v. 110, n. 11, p. 1842–57, 1999. 16
- 11 WOOD, I. K. Neuroscience: Exploring the brain. *Journal of Child and Family Studies*, Springer, v. 5, n. 3, p. 377–379, 1996. 16
- 12 AL-ANI, T.; TRAD, D. *Signal Processing and Classification Approaches for Brain-Computer Interface*. [S.l.]: Intelligent and Biosensors, 2010. 16
- 13 PFURTSCHELLER, G.; NEUPER, C. Motor imagery and direct brain-computer communication. *Proceedings of the IEEE*, IEEE, v. 89, n. 7, p. 1123–1134, 2001. 17, 23

- 14 DONCHIN E., S. K. M.; WIJESINGHE, R. The mental prosthesis: assessing the speed of a p300-based brain-computer interface. *IEEE Transactions on Rehabilitation Engineering*, IEEE, v. 8, n. 2, p. 174–179, 2000. 17
- 15 MCFARLAND, D. J.; MCCANE, L. M.; WOLPAW, J. R. Eeg-based communication and control: short-term role of feedback. *IEEE Transactions on Rehabilitation Engineering*, IEEE, v. 6, n. 1, p. 7–11, 1998. 17
- 16 HWANG, H.-J.; KWON, K.; IM, C.-H. Neurofeedback-based motor imagery training for brain-computer interface (bci). *Journal of Neuroscience Methods*, v. 179, n. 1, p. 150–156, 2009. 17
- 17 SLENES, G. F. et al. The use of fmri for the evaluation of the effect of training in motor imagery bci users. In: *International IEEE/EMBS Conference on Neural Engineering*. [S.l.: s.n.], 2013. p. 686–690. 17
- 18 AHN, M.; JUN, S. C. Performance variation in motor imagery brain-computer interface: A brief review. *Journal of Neuroscience Methods*, Elsevier, v. 243, p. 103–110, 2015. 17
- 19 RAMOS-MURGUIALDAY, A. e. a. Brain-machine interface in chronic stroke rehabilitation: A controlled study. *Annals of Neurology*, v. 74, n. 1, p. 100–108, 2013. 17
- 20 KRIZHEVSKY A., S. I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. *ImageNet Classification with Deep Convolutional Neural Networks*, p. 1097–1105, 2012. 17
- 21 FARABET, C. et al. Learning hierarchical features for scene labeling. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, IEEE, v. 35, n. 8, p. 1915–1929, 2013. 17
- 22 SZEGEDY, C. et al. Going deeper with convolutions. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, p. 1–9, 2015. 17
- 23 MIKOLOV, T. et al. Strategies for training large scale neural network language models. In: *2011 IEEE Workshop on Automatic Speech Recognition Understanding*. [S.l.: s.n.], 2011. p. 196–201. 17
- 24 SAINATH, T. et al. Deep convolutional neural networks for lvcsr. In: IEEE. *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*. [S.l.], 2013. p. 8614–8618. 17
- 25 LECUN Y., B. Y.; HINTON, G. Deep learning. *Nature*, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015. 17
- 26 GOODFELLOW I., B. Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. 17
- 27 LUO, Y.; YANG, F. Deep learning with noise. p. 1–9, 2015. 17
- 28 YIN, S. et al. Noisy training for deep neural networks in speech recognition. *EURASIP Journal on Audio, Speech, and Music Processing*, Springer, v. 2015, n. 1, p. 2, 2015. 17

- 29 YANG, B. et al. Automatic ocular artifacts removal in eeg using deep learning. *Bio-medical Signal Processing and Control*, Elsevier, v. 43, p. 148–158, 2018. 17
- 30 MASHHADI, N. et al. Deep learning denoising for eeg artifacts removal from eeg signals. In: IEEE. *2020 IEEE Global Humanitarian Technology Conference (GHTC)*. [S.l.], 2020. p. 1–6. 17
- 31 LAKSHMI, M. R.; PRASAD, T.; PRAKASH, D. V. C. Survey on eeg signal processing methods. *International journal of advanced research in computer science and software engineering*, v. 4, n. 1, 2014. 17, 18
- 32 KANOVA, S.; MITSUKURA, Y. Review of artifact rejection methods for electroencephalographic systems. In: SITTIPRAPAPORN, P. (Ed.). *Electroencephalography*. Rijeka: IntechOpen, 2017. cap. 6. Disponível em: <<https://doi.org/10.5772/68023>>. 18
- 33 ALHADDAD, M. J. Common average reference (car) improves p300 speller. *International Journal of Engineering and Technology*, v. 2, n. 3, p. 21, 2012. 18
- 34 SUTO, J.; ONIGA, S. Music stimuli recognition in electroencephalogram signal. *Elektronika ir Elektrotechnika*, v. 24, n. 4, p. 68–71, 2018. 18
- 35 CRAIK, A.; HE, Y.; CONTRERAS-VIDAL, J. L. Deep learning for electroencephalogram (eeg) classification tasks: a review. *Journal of neural engineering*, IOP Publishing, v. 16, n. 3, p. 031001, 2019. 18, 20, 24, 27, 28, 32
- 36 BOUZALMAT, A. et al. Comparative study of pca, ica, lda using svm classifier. *Journal of Emerging Technologies in Web Intelligence*, Engineering and Technology Publishing, v. 6, n. 1, p. 64–68, 2014. 18
- 37 KOBAYASHI, T.; KURIKI, S. Principal component elimination method for the improvement of s/n in evoked neuromagnetic field measurements. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 46, n. 8, p. 951–958, 1999. 18
- 38 LANG, M. et al. Automatic near real-time outlier detection and correction in cardiac interbeat interval series for heart rate variability analysis: singular spectrum analysis-based approach. *JMIR Biomedical Engineering*, JMIR Publications Inc., Toronto, Canada, v. 4, n. 1, p. e10740, 2019. 19
- 39 HANAKAWA, T.; DIMYAN, M. A.; HALLETT, M. Motor planning, imagery, and execution in the distributed motor network: a time-course study with functional mri. *Cerebral cortex*, Oxford University Press, v. 18, n. 12, p. 2775–2788, 2008. 22
- 40 DECETY, J.; JEANNEROD, M. Mentally simulated movements in virtual reality. *Does Fitts law hold in motor imagery*, 1995. 22
- 41 JEANNEROD, M. The representing brain: Neural correlates of motor intention and imagery. *Behavioral and Brain sciences*, Cambridge University Press, v. 17, n. 2, p. 187–202, 1994. 22
- 42 LOTZE, M. et al. Activation of cortical and cerebellar motor areas during executed and imagined hand movements: an fmri study. *Journal of cognitive neuroscience*, MIT Press One Rogers Street, Cambridge, MA 02142-1209, USA journals-info . . . , v. 11, n. 5, p. 491–501, 1999. 22

- 43 NUNES, G. S.; NORONHA, M. d.; JR, V. A. d. C. Motor imagery in the treatment of acute lateral ankle sprains in soccer athletes: a pilot study. *Fisioterapia e Pesquisa*, SciELO Brasil, v. 22, p. 282–290, 2015. 23
- 44 SILVA, T. B. da; FREITAS, R.; OLIVEIRA, L. C. S. de. Imagética motora e terapia por contensão induzida modificada na disfunção do membro superior pós-ave-revisão sistemática. *Journal: Revista Científica Multidisciplinar Núcleo do Conhecimento*, p. 133–166, 2021. 23
- 45 MCFARLAND, D. J.; WOLPAW, J. R. Brain-computer interfaces for communication and control. *Communications of the ACM*, ACM New York, NY, USA, v. 54, n. 5, p. 60–66, 2011. 23
- 46 RON-ANGEVIN, R. et al. Brain-computer interface application: auditory serial interface to control a two-class motor-imagery-based wheelchair. *Journal of neuroengineering and rehabilitation*, BioMed Central, v. 14, n. 1, p. 1–16, 2017. 23
- 47 KÜBLER, A. et al. Brain-computer communication: Unlocking the locked in. *Psychological bulletin*, American Psychological Association, v. 127, n. 3, p. 358, 2001. 23
- 48 KHAN, M. A. et al. Review on motor imagery based bci systems for upper limb post-stroke neurorehabilitation: From designing to application. *Computers in Biology and Medicine*, Elsevier, v. 123, p. 103843, 2020. 23
- 49 BARRY, R. J. et al. Eeg differences between eyes-closed and eyes-open resting conditions. *Clinical neurophysiology*, Elsevier, v. 118, n. 12, p. 2765–2773, 2007. 24
- 50 NUNEZ, P. L.; SRINIVASAN, R. A theoretical basis for standing and traveling brain waves measured with human eeg with implications for an integrated consciousness. *Clinical neurophysiology*, Elsevier, v. 117, n. 11, p. 2424–2435, 2006. 24
- 51 LIU, T.; YAO, D. Removal of the ocular artifacts from eeg data using a cascaded spatio-temporal processing. *Computer methods and programs in biomedicine*, Elsevier, v. 83, n. 2, p. 95–103, 2006. 24
- 52 LESKE, S.; DALAL, S. S. Reducing power line noise in eeg and meg data via spectrum interpolation. *Neuroimage*, Elsevier, v. 189, p. 763–776, 2019. 24
- 53 PIEPER, K. et al. Working with environmental noise and noise-cancelation: A workload assessment with eeg and subjective measures. *Frontiers in neuroscience*, Frontiers Research Foundation, Lausanne, v. 15, p. 771533–771533, 2021. ISSN 1662-453X. 24
- 54 SUBASI, A.; GURSOY, M. I. Eeg signal classification using pca, ica, lda and support vector machines. *Expert systems with applications*, Elsevier, v. 37, n. 12, p. 8659–8666, 2010. 24
- 55 HUANG, Z.; WANG, M. A review of electroencephalogram signal processing methods for brain-controlled robots. *Cognitive Robotics*, Elsevier, v. 1, p. 111–124, 2021. 24
- 56 PAWAR, D.; DHAGE, S. Feature extraction methods for electroencephalography based brain-computer interface: A review. *IAENG International Journal of Computer Science*, v. 47, n. 3, 2020. 24

- 57 XIE, Y.; ONIGA, S. A review of processing methods and classification algorithm for eeg signal. *Carpathian Journal of Electronic & Computer Engineering*, v. 12, n. 3, 2020. 24
- 58 CAO, L. et al. A comparison of pca, kpca and ica for dimensionality reduction in support vector machine. *Neurocomputing*, Elsevier, v. 55, n. 1-2, p. 321–336, 2003. 25, 26
- 59 HART, P. E.; STORK, D. G.; DUDA, R. O. *Pattern classification*. [S.l.]: Wiley Hoboken, 2000. 25, 26
- 60 WIDODO, A.; YANG, B.-S. Application of nonlinear feature extraction and support vector machines for fault diagnosis of induction motors. *Expert Systems with Applications*, Elsevier, v. 33, n. 1, p. 241–250, 2007. 25, 26
- 61 TONG, S. et al. Removal of eeg interference from the eeg recordings in small animals using independent component analysis. *Journal of Neuroscience Methods*, v. 108, n. 1, p. 11–17, 2001. ISSN 0165-0270. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0165027001003661>>. 25, 27
- 62 ÇİNAR, S.; ACİR, N. A novel system for automatic removal of ocular artefacts in eeg by using outlier detection methods and independent component analysis. *Expert Systems with Applications*, v. 68, p. 36–44, 2017. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417416305401>>. 25
- 63 HYVÄRINEN, A.; OJA, E. Independent component analysis: algorithms and applications. *Neural networks*, Elsevier, v. 13, n. 4-5, p. 411–430, 2000. 25
- 64 LEE, T.-W. et al. Blind source separation of more sources than mixtures using over-complete representations. *IEEE signal processing letters*, IEEE, v. 6, n. 4, p. 87–90, 1999. 25
- 65 AGARWAL, S.; ZUBAIR, M. Classification of alcoholic and non-alcoholic eeg signals based on sliding-ssa and independent component analysis. *IEEE Sensors Journal*, IEEE, v. 21, n. 23, p. 26198–26206, 2021. 26, 27
- 66 MOHAMMADI, S. M. et al. Improving time–frequency domain sleep eeg classification via singular spectrum analysis. *Journal of neuroscience methods*, Elsevier, v. 273, p. 96–106, 2016. 26
- 67 RAMANNA, S.; TIRUNAGARI, S.; WINDRIDGE, D. Epileptic seizure detection using constrained singular spectrum analysis and 1d-local binary patterns. *Health and Technology*, Springer, v. 10, n. 3, p. 699–709, 2020. 26
- 68 AMABILE, R. A. et al. Remoção automática de artefatos em sinais de eeg usando local ssa. In: *XVII Congresso Brasileiro de Automática*. [S.l.: s.n.], 2008. 26, 27
- 69 GOLYANDINA, N.; NEKRUTKIN, V.; ZHIGLJAVSKY, A. A. *Analysis of time series structure: SSA and related techniques*. [S.l.]: CRC press, 2001. 27, 42, 63
- 70 ZHANG, Y. et al. An investigation of deep learning models for eeg-based emotion recognition. *Frontiers in Neuroscience*, Frontiers Media SA, v. 14, p. 622759, 2020. 27

- 71 ZHANG, C.; KIM, Y.-K.; ESKANDARIAN, A. Eeg-inception: an accurate and robust end-to-end neural network for eeg-based motor imagery classification. *Journal of Neural Engineering*, IOP Publishing, v. 18, n. 4, p. 046014, 2021. 27
- 72 DU, Y.; LIU, J. Ienet: a robust convolutional neural network for eeg based brain-computer interfaces. *Journal of Neural Engineering*, IOP Publishing, v. 19, n. 3, p. 036031, jun 2022. Disponível em: <<https://dx.doi.org/10.1088/1741-2552/ac7257>>. 27
- 73 AGGARWAL, S.; CHUGH, N. Review of machine learning techniques for eeg based brain computer interface. *Archives of Computational Methods in Engineering*, Springer, p. 1–20, 2022. 28
- 74 LOTTE, F. et al. A review of classification algorithms for eeg-based brain-computer interfaces: A 10-year update. *Journal of Neural Engineering*, v. 15, 02 2018. 28
- 75 SCHALK, G. et al. Bci2000: a general-purpose brain-computer interface (bci) system. *IEEE Transactions on biomedical engineering*, IEEE, v. 51, n. 6, p. 1034–1043, 2004. 29
- 76 GOLDBERGER, A. L. et al. Physiobank, physiotoolkit, and physionet: components of a new research resource for complex physiologic signals. *circulation*, Am Heart Assoc, v. 101, n. 23, p. e215–e220, 2000. 29
- 77 COMMONS, W. *File:EEG 10-10 system with additional information.svg* — *Wikimedia Commons, the free media repository*. 2023. [Online; accessed 8-July-2023]. Disponível em: <https://commons.wikimedia.org/w/index.php?title=File:EEG_10-10_system_with_additional_information.svg&oldid=733795147>. 30
- 78 GRIGOREV, N. et al. A bci-based vibrotactile neurofeedback training improves motor cortical excitability during motor imagery. *bioRxiv*, Cold Spring Harbor Laboratory, 2021. Disponível em: <<https://www.biorxiv.org/content/early/2021/03/01/2021.02.28.433220>>. 31
- 79 LOBODA, A. et al. Discrimination of eeg-based motor imagery tasks by means of a simple phase information method. *International Journal of Advanced Research in Artificial Intelligence*, Citeseer, v. 3, n. 10, 2014. 32
- 80 SANEI, S.; CHAMBERS, J. A. *EEG signal processing*. [S.l.]: John Wiley & Sons, 2013. 34
- 81 GAO, J.; HU, J.; TUNG, W.-w. Complexity measures of brain wave dynamics. *Cognitive neurodynamics*, Springer, v. 5, p. 171–182, 2011. 34
- 82 SILVA, L. E. et al. Multivariate statistical analysis of eeg signals for dementia diagnosis. *Physica A: Statistical Mechanics and its Applications*, Elsevier, v. 461, p. 295–302, 2016. 34
- 83 PEARSON, E. S.; ‘AGOSTINO, R. B. D.; BOWMAN, K. O. Tests for departure from normality: Comparison of powers. *Biometrika*, Oxford University Press, v. 64, n. 2, p. 231–246, 1977. 34
- 84 VIRTANEN, P. et al. SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python. *Nature Methods*, v. 17, p. 261–272, 2020. 34

- 85 HYVÄRINEN, A.; KARHUNEN, J.; OJA, E. *Independent Component Analysis*. [S.l.: s.n.], 2001. v. 26. ISBN 9780471405405. 35
- 86 ZOUBIR, A. M.; BOASHASH, B. The bootstrap and its application in signal processing. *IEEE Signal processing magazine*, IEEE, v. 15, n. 1, p. 56–76, 1998. 35
- 87 JOLLIFFE, I. T. *Principal component analysis*. [S.l.]: Springer, 2002. 35
- 88 PATRO, S.; SAHU, K. Normalization: A preprocessing stage. *IARJSET*, v. 20-22, 2015. 35
- 89 MNE.PREPROCESSING.ICA. Disponível em: <<https://mne.tools/stable/generated/mne.preprocessing.ICA.html>>. 37
- 90 ABLIN, P.; CARDOSO, J.-F.; GRAMFORT, A. Faster independent component analysis by preconditioning with hessian approximations. *IEEE Transactions on Signal Processing*, v. 66, n. 15, p. 4040–4049, 2018. 38
- 91 LI, A. et al. Mne-icalabel: Automatically annotating ica components with iclabel in python. *Journal of Open Source Software*, v. 7, n. 76, p. 4484, 2022. 38
- 92 TANGERMANN, M. et al. Review of the bci competition iv. *Frontiers in neuroscience*, Frontiers, p. 55, 2012. 39, 56, 57
- 93 PION-TONACHINI, L.; KREUTZ-DELGADO, K.; MAKEIG, S. The iclabel dataset of electroencephalographic (eeg) independent component (ic) features. *Data in brief*, Elsevier, v. 25, p. 104101, 2019. 39
- 94 PION-TONACHINI, L.; MAKEIG, S.; KREUTZ-DELGADO, K. Crowd labeling latent dirichlet allocation. *Knowledge and information systems*, Springer, v. 53, n. 3, p. 749–765, 2017. 39
- 95 ICLABEL tutorial: EEG Independent Component Labeling. Disponível em: <<https://labeling.ucsd.edu/tutorial/overview>>. 39, 69
- 96 PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011. 40
- 97 KIEFERK, J. *Kieferk/pymssa: Python implementation of Multivariate Singular Spectrum Analysis (MSSA)*. Disponível em: <<https://github.com/kieferk/pymssa>>. 41
- 98 FAOUZI, J.; JANATI, H. pyts: A python package for time series classification. *Journal of Machine Learning Research*, v. 21, n. 46, p. 1–6, 2020. Disponível em: <<http://jmlr.org/papers/v21/19-763.html>>. 41
- 99 GOLYANDINA, N. On the choice of parameters in singular spectrum analysis and related subspace-based methods. *arXiv preprint arXiv:1005.4374*, 2010. 42, 62
- 100 HASSANI, H. Singular spectrum analysis: methodology and comparison. Cardiff University and Central Bank of the Islamic Republic of Iran, 2007. 43, 64
- 101 LAWHERN, V. J. et al. Eegnet: a compact convolutional neural network for eeg-based brain–computer interfaces. *Journal of neural engineering*, IOP Publishing, v. 15, n. 5, p. 056013, 2018. 45

- 102 GULLI, A.; PAL, S. *Deep learning with Keras*. [S.l.]: Packt Publishing Ltd, 2017. 45
- 103 ABADI, M. et al. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*. 2015. Software available from tensorflow.org. Disponível em: <<https://www.tensorflow.org/>>. 45
- 104 CHETLUR, S. et al. cudnn: Efficient primitives for deep learning. *arXiv preprint arXiv:1410.0759*, 2014. 45
- 105 HENDRYCKS, D.; GIMPEL, K. Gaussian error linear units (gelus). *arXiv preprint arXiv:1606.08415*, 2016. 46
- 106 BERGSTRA, J.; YAMINS, D.; COX, D. Making a science of model search: Hyperparameter optimization in hundreds of dimensions for vision architectures. In: PMLR. *International conference on machine learning*. [S.l.], 2013. p. 115–123. 46
- 107 SAMMUT, C.; WEBB, G. I. *Encyclopedia of machine learning*. [S.l.]: Springer Science & Business Media, 2011. 47
- 108 MCHUGH, M. L. Interrater reliability: the kappa statistic. *Biochemia medica, Medicinska naklada*, v. 22, n. 3, p. 276–282, 2012. 48
- 109 SIM, J.; WRIGHT, C. C. The kappa statistic in reliability studies: use, interpretation, and sample size requirements. *Physical therapy*, Oxford University Press, v. 85, n. 3, p. 257–268, 2005. 48
- 110 KIM, T. K. Understanding one-way anova using conceptual figures. *Korean journal of anesthesiology*, The Korean Society of Anesthesiologists, v. 70, n. 1, p. 22–26, 2017. 48
- 111 SLEIGHT, J.; PILLAI, P.; MOHAN, S. Classification of executed and imagined motor movement eeg signals. *Ann Arbor: University of Michigan*, v. 110, 2009. 54
- 112 SCHIRRMESTER, R. T. et al. Deep learning with convolutional neural networks for eeg decoding and visualization. *Human brain mapping*, Wiley Online Library, v. 38, n. 11, p. 5391–5420, 2017. 56
- 113 LU, N. et al. A deep learning scheme for motor imagery classification based on restricted boltzmann machines. *IEEE transactions on neural systems and rehabilitation engineering*, IEEE, v. 25, n. 6, p. 566–576, 2016. 56
- 114 YU, Z.; SONG, J. Multi-class motor imagery classification by singular value decomposition and deep boltzmann machine. In: IEEE. *2017 IEEE 3rd Information Technology and Mechatronics Engineering Conference (ITOEC)*. [S.l.], 2017. p. 376–379. 56
- 115 WANG, P. et al. Lstm-based eeg classification in motor imagery tasks. *IEEE transactions on neural systems and rehabilitation engineering*, IEEE, v. 26, n. 11, p. 2086–2095, 2018. 56
- 116 KOBLER, R. J.; SCHERER, R. Restricted boltzmann machines in sensory motor rhythm brain-computer interfacing: a study on inter-subject transfer and co-adaptation. In: IEEE. *2016 IEEE international conference on systems, man, and cybernetics (SMC)*. [S.l.], 2016. p. 000469–000474. 56

- 117 LUO, T.-j.; ZHOU, C.-l.; CHAO, F. Exploring spatial-frequency-sequential relationships for motor imagery classification with recurrent neural network. *BMC bioinformatics*, BioMed Central, v. 19, n. 1, p. 1–18, 2018. 56
- 118 TABAR, Y. R.; HALICI, U. A novel deep learning approach for classification of eeg motor imagery signals. *Journal of neural engineering*, IOP Publishing, v. 14, n. 1, p. 016003, 2016. 56
- 119 ABBAS, W.; KHAN, N. A. Deepmi: Deep learning for multiclass motor imagery classification. In: IEEE. *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. [S.l.], 2018. p. 219–222. 56
- 120 SAKHAVI, S.; GUAN, C.; YAN, S. Learning temporal information for brain-computer interface using convolutional neural networks. *IEEE transactions on neural networks and learning systems*, IEEE, v. 29, n. 11, p. 5619–5629, 2018. 56
- 121 CHU, Y. et al. A decoding scheme for incomplete motor imagery eeg with deep belief network. *Frontiers in neuroscience*, Frontiers Media SA, v. 12, p. 680, 2018. 56
- 122 FADEL, W. et al. Multi-class classification of motor imagery eeg signals using image-based deep recurrent convolutional neural network. In: IEEE. *2020 8th International Winter Conference on Brain-Computer Interface (BCI)*. [S.l.], 2020. p. 1–4. 56
- 123 SAKHAVI, S.; GUAN, C.; YAN, S. Parallel convolutional-linear neural network for motor imagery classification. In: IEEE. *2015 23rd European Signal Processing Conference (EUSIPCO)*. [S.l.], 2015. p. 2736–2740. 56
- 124 DOSE, H. et al. An end-to-end deep learning approach to mi-eeg signal classification for bcis. *Expert Systems with Applications*, Elsevier, v. 114, p. 532–542, 2018. 56
- 125 MA, X. et al. Improving eeg-based motor imagery classification via spatial and temporal recurrent neural networks. In: IEEE. *2018 40th annual international conference of the IEEE engineering in medicine and biology society (EMBC)*. [S.l.], 2018. p. 1903–1906. 56
- 126 SHE, Q. et al. A hierarchical semi-supervised extreme learning machine method for eeg recognition. *Medical & biological engineering & computing*, Springer, v. 57, p. 147–157, 2019. 56
- 127 HASSANI, H.; HERAVI, S.; ZHIGLJAVSKY, A. Forecasting european industrial production with singular spectrum analysis. *International journal of forecasting*, Elsevier, v. 25, n. 1, p. 103–118, 2009. 63