



UNIVERSIDADE FEDERAL DO PARÁ
CAMPUS UNIVERSITÁRIO DE TUCURUÍ
FACULDADE DE ENGENHARIA ELÉTRICA

LEILANE DE JESUS ANJOS

INTERFACE CÉREBRO-MÁQUINA: UMA ABORDAGEM ÓTIMA VIA DISTÂNCIA DE
RIEMANN POR SUBBANDA.

TUCURUÍ

2024

LEILANE DE JESUS ANJOS

INTERFACE CÉREBRO-MÁQUINA: UMA ABORDAGEM ÓTIMA VIA DISTÂNCIA DE
RIEMANN POR SUBBANDA.

Trabalho de Conclusão de Curso, apresentado
como requisito parcial para a obtenção de
grau de Bacharel em Engenharia Elétrica,
pela Universidade Federal do Pará.

Orientador:
Prof. Dr. Cleison Daniel Silva.

TUCURUÍ

2024

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)**

D278i de Jesus dos Anjos, Leilane.
Interface Cérebro-Máquina : uma abordagem ótima via
distância de Riemann por subbandas / Leilane de Jesus dos Anjos.
— 2024.
23 f. : il. color.

Orientador(a): Prof. Dr. Cleison Daniel Silva
Trabalho de Conclusão (Graduação) - Universidade Federal do
Pará, Campus Universitário de Tucuruí, Faculdade de Engenharia
Civil, Tucuruí, 2024.

1. Geometria de Riemann. 2. Otimização Bayesiana. 3.
Interface-Cérebro- Máquina. I. Título.

CDD 620.00285

LEILANE DE JESUS ANJOS

Interface Cérebro-Máquina: uma abordagem ótima via distância de Riemann por subbanda.

Trabalho de Conclusão de Curso, apresentado como requisito parcial para a obtenção de grau de Bacharel em Engenharia Elétrica, pela Universidade Federal do Pará.

Data de aprovação: 01 de novembro de 2024.

Banca Examinadora:

Prof. Dr. Cleison Daniel Silva
Orientador - FEE/CAMTUC/UFPA

Prof. Dr. Raphael Barros Teixeira
Avaliador Interno - FEE/CAMTUC/UFPA

Prof. Dr. Iago Lins de Medeiros
Avaliador Externo -
FECOMP/CAMTUC/UFPA

TUCURUÍ

2024



UNIVERSIDADE FEDERAL DO PARÁ
CAMPUS UNIVERSITÁRIO DE TUCURUÍ
FACULDADE DE ENGENHARIA ELÉTRICA

TÍTULO: Interface Cérebro-Máquina: uma abordagem ótima via distância de Riemann por subbanda.

DISCENTE: Leilane de Jesus dos Anjos

MATRÍCULA: 202033940025

#	BANCA EXAMINADORA	CONDIÇÃO
1	<i>Prof. Dr. Cleison Daniel Silva –FEE-UFPA</i>	<i>Orientador</i>
2	<i>Prof. Dr. Raphael Barros Teixeira – FEE-UFPA</i>	<i>Membro</i>
3	<i>Prof. Me. Iago Lins de Medeiros –FECOMP-UFPA</i>	<i>Membro</i>

Data da Defesa: 01/11/2024 | **Hora Início:** 15:30h | **Hora Término:** 17:00h

Trabalho Escrito (0 a 10 pontos por critério)	Examinador 1	Examinador 2	Examinador 3
Formatação	9,5	9,5	9,0
Linguagem (gramática e semântica)	9,5	10	9,5
Conteúdo técnico	10	10	10

Defesa Oral (0 a 10 pontos por critério)	Examinador 1	Examinador 2	Examinador 3
Sequência lógica de apresentação	10	10	10
Administração do tempo	10	10	10
Expressão oral	10	10	10
Domínio do tema	10	10	10

Média por examinador	9,86	9,93	9,79
Média Final	9,86		
Conceito Final	EXCELENTE		

Tucuruí-PA, 05 de novembro de 2024.

Cleison D. Silva

Raphael B. Teixeira

Iago L. Medeiros

Dedico aos meus familiares, em especial aos meus pais pelo esforço na minha educação e a todos os amigos pelo apoio, incentivo e confiança no decorrer da longa jornada de formação acadêmica.

AGRADECIMENTOS

Primeiramente, agradeço a Deus por me dar saúde, força, sabedoria e perseverança nesta jornada que marca uma etapa importante na minha vida.

Aos meus pais, Maria dos Milagres e José Francisco, expresso meus mais sinceros agradecimentos. Vocês foram as pessoas que mais me motivaram a realizar esta conquista. Seus ensinamentos e seu comprometimento com meus estudos me fizeram chegar até aqui.

Os meu irmãos e irmãs, minha eterna gratidão. Vocês foram uma fonte constante de motivação e inspiração que direta ou indiretamente contribuíram para que eu pudesse alcançar este objetivo.

Gostaria de agradecer também ao meu orientador Dr. Cleison Daniel Silva. Minha gratidão pela paciência, dedicação e conhecimento compartilhado, que auxiliou não apenas no desenvolvimento deste TCC mas também auxiliaram no meu desenvolvimento acadêmico.

A todos os demais professores da UFPA, que compartilharam seus conhecimentos, contribuindo para o meu desenvolvimento acadêmico.

Aos meus amigos e colegas de graduação que durante todo este período compartilharam momentos de alegrias, desafios e aprendizados tornando esta jornada mais leve e repleta de boas lembranças que levarei comigo.

Deixo aqui a expresso a minha gratidão à PIBIC e à FAPESPA pelo suporte financeiro permitindo com que fosse possível o desenvolvimento deste projeto.

Mais uma vez, meus mais sinceros agradecimentos a todos que me acompanharam até este momento, contribuindo para este trabalho e para a minha jornada acadêmica como um todo.

RESUMO

Este trabalho, apresenta o relatório de pesquisa intitulado "Interface Cérebro-Máquina: uma abordagem ótima via distância de Riemann", desenvolvido entre 01 de setembro de 2023 à 31 de agosto de 2024, durante a execução do projeto de pesquisa denominado "Técnicas de otimização aplicadas a Interface Cérebro-Máquina", financiado pela Fundação Amazônica de Amparo a Estudos e Pesquisas, sob orientação do professor Dr. Cleison Daniel Silva. Este trabalho foi elaborado seguindo a resolução nº1/2024 da Faculdade de Engenharia Elétrica- CAMTUC, que regulamenta os termos da flexibilização do Trabalho de Conclusão de Curso na IN nº5/2023 da PROEG-UFPA. Sistemas de Interface Cérebro Máquina (ICM) são tecnologias capazes realizar a comunicação entre o cérebro humano e dispositivos externos, a partir de sinais neurais, que podem ser coletadas, através de técnicas de neuroimagem como a eletroencefalografia (EEG), processadas e convertidas em comandos. O estudo da pesquisa, concentra-se em melhorar o desempenho de classificação em sistemas de ICM baseados em imagética motora usando o método de Mínima distância a Média de Riemann (do inglês *Minimum Distance to Riemann Mean - MDRM*) através do algoritmo de classificação Distância Mínima à Média (do inglês *Minimum Distance to Mean - MDM*) para a extração de informações discriminantes a partir de sinais de EEG representados por matrizes de covariância simétricas positivas definidas por sub-banda, formando uma representação normalizada dos sinais de EEG que são entregues ao algoritmo de classificação Máquina de Vetor de Suporte (do inglês *Support Vector Machine*). Os hiperparâmetros relacionados a faixa de frequência de interesse, número de sub-bandas e parâmetros do classificador, são ajustados por meio da Otimização Bayesiana de modo a lidar com as características inter e intra sujeitos, permitindo ajustes individuais. Os resultados obtidos a partir de um conjunto de dados públicos apresentaram melhorias significativas em comparação como um método previamente proposto. A acurácia do classificador foi utilizada para a comparação, servido de base para discussões e conclusões da pesquisa.

— **Palavras-chave:** Geometria de Riemann; Otimização Bayesiana; Interface-Cérebro-Máquina;

ABSTRACT

This work presents the research report titled "Brain-Machine Interface: an optimal approach via Riemannian distance," developed from September 1, 2023, to August 31, 2024, during the execution of the research project named "Optimization techniques applied to Brain-Machine Interface," funded by the Amazon Foundation for Research Support, under the supervision of Professor Dr. Cleison Daniel Silva. This work was prepared following resolution n°1/2024 of the Faculty of Electrical Engineering - CAMTUC, which regulates the terms of the flexibilization of the Final Graduation Project in IN n°5/2023 of PROEG-UFPA. Brain-Machine Interface (BMI) systems are technologies capable of establishing communication between the human brain and external devices through neural signals, which can be collected via neuroimaging techniques such as electroencephalography (EEG), processed, and converted into commands. The research study focuses on improving classification performance in motor imagery-based BMI systems using the Minimum Distance to Riemannian Mean (MDRM) method through the Minimum Distance to Mean (MDM) classification algorithm for extracting discriminative information from EEG signals represented by positive definite symmetric covariance matrices defined by sub-bands, forming a normalized representation of the EEG signals that are fed into the Support Vector Machine (SVM) classification algorithm. The hyperparameters related to the frequency band of interest, the number of sub-bands, and classifier parameters are adjusted through Bayesian Optimization to address inter- and intra-subject characteristics, allowing for individual adjustments. The results obtained from a public dataset showed significant improvements compared to a previously proposed method. The classifier's accuracy was used for comparison, serving as the basis for discussions and conclusions of the research.

Keywords: *Riemann Geometry, Bayesian Optimization, Brain-Computer Interface.*

SUMÁRIO

1	TEXTO DE APRESENTAÇÃO	10
	Referências	12
	ANEXO A – INTERFACE CÉREBRO-MÁQUINA: UMA ABOR- DAGEM ÓTIMA VIA DISTÂNCIA DE RIE- MANN POR SUBBANDA.	13

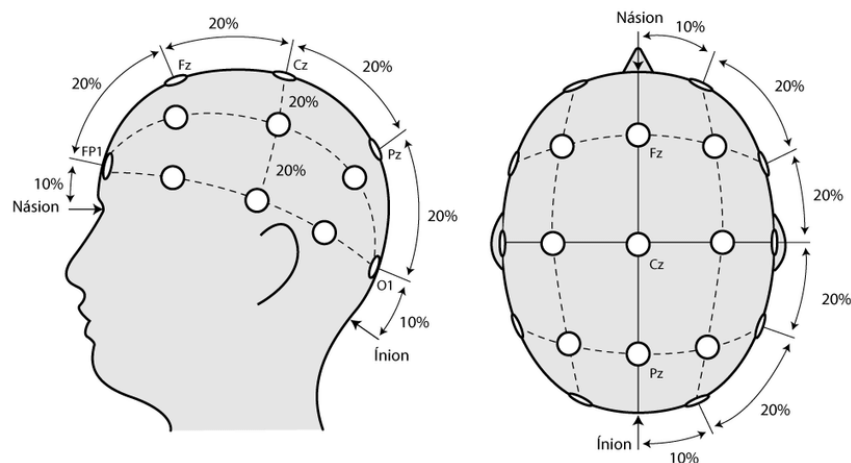
1 TEXTO DE APRESENTAÇÃO

As Interfaces Cérebro-Máquina (ICMs), são conhecidas como sistemas que permitem a comunicação entre o cérebro humano e dispositivos externos, à partir da coleta, do processamento e da decodificação de sinais cerebrais (CLERC; BOUGRAIN; LOTTE, 2016). Em geral, uma ICM é capaz de interpretar a intenção do usuário, por meio do monitoramento dos sinais cerebrais, e convertê-lo em comandos que podem ser direcionados a controle de próteses, de computadores, de cadeiras de rodas, de drones, entre outros (KIM; LEE, 2014; AKRAM; HAN; KIM, 2014; CHINBAT; LIN, 2018; LEE et al., 2021).

Dentre os fenômenos neurofisiológicos empregados para interpretar a intenção do usuário de uma ICM, a Imagética Motora (IM) destaca-se como uma das mais utilizadas. Uma vez que, por não necessitar de estímulos externos, como luz ou som, para ativar ou modular a atividade neural, confere ao usuário autonomia na modulação de seus próprios sinais cerebrais (BOAS; MENDES et al., 2021). Neste contexto, a IM se configura como a capacidade do usuário de gerar padrões de atividade cerebral que refletem sua intenção motora, utilizando apenas a imaginação do movimento.

De modo geral, quando executado, gera um aumento de atividade cerebral na região sensório-motora do córtex, que, entre outras funções, é responsável por controlar o sistema neuromuscular, o qual abrange os membros periféricos do corpo humano (SILVERTHORN, 2017). Para realizar a aquisição destes sinais, umas das abordagens mais comuns e amplamente utilizadas na literatura é o uso da técnica de neuroimagem conhecida como eletroencefalografia (EEG), dada a sua alta resolução temporal, baixo custo de aquisição e por ser uma técnica não invasiva (NICOLAS-ALONSO; GOMEZ-GIL, 2012). Ela utiliza de eletrodos conectados ao couro cabeludo do indivíduo, como mostra a Figura 1.

Figura 1 – Posição dos eletrodos no sistema 10-20.



Fonte: (RODRIGUES, 2018).

No entanto, apesar de sua eficácia, os sinais de EEG são altamente suscetíveis a ruídos, o que afeta o desempenho e classificação de imagética motora em sistemas ICM, tornando desafiadora a extração de características que expressem a intenção do usuário (LOPES et al., 2023). Neste cenário, diferentes técnicas que objetivem o melhoramento do processamento dos sinais de EEG, foram desenvolvidos ao longo dos anos e são bem difundidos na literatura atual.

Neste contexto, o relatório apresentado neste trabalho resultado do projeto de pesquisa intitulado "Técnicas de otimização aplicadas a sistemas de Interface Cérebro-Máquina", orientado pelo professor Dr. Cleison Daniel Silva no período de 1 setembro de 2023 a 31 de agosto de 2024, apresenta uma nova abordagem no que diz respeito a eficácia de classificação de sinais de EEG associados a imagética motora, realizada após uma revisão bibliográfica sobre sistemas ICM, otimização Bayesiana e o método de Mínima distância para a média de Riemann (do inglês, *Minimum Distance to Riemann Mean - MDRM*).

A abordagem busca utilizar da geometria riemanianna, a partir do algoritmo MDRM, para a extração de informações discriminantes de imagética motora ao utilizar as matrizes de covariância simétricas positivas definidas (SPD) dos sinais de EEG filtrados temporalmente como *features* para classificação. Além disso, é empregado a técnica de otimização bayesiana para seleção dos melhores hiperparâmetros que envolvem as etapas de pré-processamento e classificação, para cada indivíduo em um conjunto público de dados, visando melhorar a eficiência da classificação de imagética motora.

A escolha do algoritmo MDRM é motivada pelas características únicas das matrizes SPD que se encontram em um espaço de variedade diferencial com estrutura não euclidiana, permitindo utilizar da métrica de Riemann, para capturar de maneira mais apropriada as distâncias entre matrizes de covariância com relação a sua média, permitindo uma discriminação mais robusta entre diferentes classes de dados ao realçar as diferenças entre os estados de imagética motora (BARACHANT et al., 2013).

A partir dos resultados obtidos através das ferramentas utilizadas, foram alcançados resultados significativos quando comparados com os apresentados por Congedo, Barachant e Andreev em sua pesquisa: *A new generation of brain-computer interface based on riemannian geometry*. O que acarretou no desenvolvimento do relatório final do projeto de pesquisa.

O trabalho em questão foi apresentado como parte integrante do Trabalho de Conclusão de Curso, por meio de uma estratégia de flexibilização, definida pela INSTRUÇÃO NORMATIVA Nº 05/2023 – PROEG/UFPA, e a utilização do trabalho com o objetivo proposto, tem autorização dos demais autores e coordenadores do trabalho original, como declarado na autorização em anexo, e anuência do colegiado da Faculdade de Engenharia Elétrica.

Referências

- AKRAM, F.; HAN, H.-S.; KIM, T.-S. A p300-based brain computer interface system for words typing. *Computers in biology and medicine*, Elsevier, v. 45, p. 118–125, 2014. Citado na página 10.
- BARACHANT, A. et al. Classification of covariance matrices using a riemannian-based kernel for bci applications. *Neurocomputing*, Elsevier, v. 112, p. 172–178, 2013. Citado na página 11.
- BOAS, V.; MENDES, V. et al. Autobci: interface cérebro-máquina com configuração hiperparamétrica automatizada. Universidade Federal do Pará, 2021. Citado na página 10.
- CHINBAT, O.; LIN, J.-S. Prosthetic arm control by human brain. In: *2018 International Symposium on Computer, Consumer and Control (IS3C)*. [S.l.: s.n.], 2018. p. 54–57. Citado na página 10.
- CLERC, M.; BOUGRAIN, L.; LOTTE, F. *Brain-computer interfaces 1: Methods and perspectives*. [S.l.]: John Wiley & Sons, 2016. Citado na página 10.
- KIM, K.-T.; LEE, S.-W. Steady-state somatosensory evoked potentials for brain-controlled wheelchair. In: *2014 International Winter Workshop on Brain-Computer Interface (BCI)*. [S.l.: s.n.], 2014. p. 1–2. Citado na página 10.
- LEE, D.-H. et al. Design of an eeg-based drone swarm control system using endogenous bci paradigms. In: *2021 9th International Winter Conference on Brain-Computer Interface (BCI)*. [S.l.: s.n.], 2021. p. 1–5. Citado na página 10.
- LOPES, D. d. S. et al. Sistemas de interface cérebro-máquina: classificação de imagética motora via geometria de riemann com otimização bayesiana. 2023. Citado na página 11.
- NICOLAS-ALONSO, L. F.; GOMEZ-GIL, J. Brain computer interfaces, a review. *sensors*, Molecular Diversity Preservation International, v. 12, n. 2, p. 1211–1279, 2012. Citado na página 10.
- RODRIGUES, P. *Extração de características em Interfaces cérebro-máquina utilizando métricas de redes complexas*. Tese (Doutorado) — Dissertation for Master in Biomedical Engineering, 2018. Citado na página 10.
- SILVERTHORN, D. U. *Fisiologia humana: uma abordagem integrada*. [S.l.]: Artmed editora, 2017. Citado na página 10.

**ANEXO A – INTERFACE CÉREBRO-MÁQUINA: UMA ABORDAGEM
ÓTIMA VIA DISTÂNCIA DE RIEMANN POR SUBBANDA.**

Na próxima página encontrará-se o arquivo original do relatório de pesquisa intitulado "Interface Cérebro-Máquina: uma abordagem ótima via distância de Riemann por subbanda"

Interface Cérebro-Máquina: uma abordagem ótima via distância de Riemann por subbanda

Leilane de Jesus Anjos

Universidade Federal de Pará, Brasil
leilanej.anjos@gmail.com,

Abstract.

Brain-Computer Interface systems based on Motor Imagery decode the user's motor intention from electroencephalography (EEG) signals and convert them into control commands applied to devices external to the human body. This paper explores the decoding of motor imagery from covariance matrices of EEG signals after filtering by a filter bank, forming a normalized and augmented representation of the signals delivered to the classification algorithm *Support Vector Machine*. The hyperparameters of the proposed system are optimized via Bayesian Optimization. The results obtained in a public dataset, in terms of classification accuracy, indicate an average increase of 5.86% and 11.26%, respectively, in the two cases studied.

CCS Concepts: • **Computing methodologies** → **Machine learning algorithms**.

Keywords: Riemann Geometry, Bayesian Optimization, Brain-Computer Interface

1. INTRODUÇÃO

As Interfaces Cérebro-Máquina (ICM) foram inicialmente desenvolvidas para auxiliar na reabilitação de indivíduos com habilidades motoras comprometidas, possibilitando a comunicação direta entre o cérebro e um dispositivo externo ao corpo humano através da conversão das oscilações elétricas dos sinais cerebrais em instruções de controle [Huang et al. 2022], [Luck 2014].

Em geral, tais oscilações podem ser medidas ao se posicionar eletrodos em diferentes regiões do escalpo e analisar diferentes bandas de frequência dos sinais coletados [Altindış and Yilmaz 2022]. Este estudo, no entanto, enfatiza os ritmos sensório-motores (SMRs), que são predominantemente detectados nas faixas de frequência $\mu \{8 - 13 \text{ Hz}\}$ e $\beta \{13 - 30 \text{ Hz}\}$. Os SMRs podem ser modulados pela execução ou imagética motora (IM) e medidos por técnicas de eletroencefalografia (EEG) [Nicolas-Alonso and Gomez-Gil 2012].

No entanto, os sinais de EEG são altamente suscetíveis a ruídos, o que pode reduzir o desempenho e a precisão dos sistemas de ICM na discriminação das tarefas de IM, afetando a confiabilidade do sistema. Embora existam técnicas de pré-processamento eficazes para reduzir esses ruídos, como o apresentado em [Kang et al. 2014], é essencial que os sistemas ICM continuem a aprimorar a precisão na decodificação das tarefas de IM executadas pelo indivíduo.

Nesse contexto, sabe-se que o desempenho dos sistemas de Interface Cérebro-Máquina baseados em Imagética Motora (ICM-IM) podem ser aprimorados ao considerar configurações específicas para cada usuário [Müller-Putz et al. 2017]. Dadas as características inter e intra sujeitos a calibração nos sistemas de ICM-IM exigem um ajuste individual com relação aos parâmetros que podem ser

Os autores agradecem a Fundação Amazônia de Amparo a Estudos e Pesquisas (FAPESPA, Código: PRO5714-2024). O trabalho foi desenvolvido no Laboratório de Inteligência, Controle e Eletrônica - LINCE/ UFPA-Tucuruí. Copyright©2024 Permission to copy without fee all or part of the material printed in KDMiLe is granted provided that the copies are not made or distributed for commercial advantage, and that notice is given that copying is by permission of the Sociedade Brasileira de Computação.

associados às etapas de processamento e classificação [Saha and Baumert 2020].

Na cadeia de processamento, uma técnica amplamente utilizada consiste em transformar trechos dos sinais de EEG em matrizes de covariância e, em seguida, tratar a decodificação dos sinais através de medidas de similaridade no espaço não-Euclidiano de matrizes Simétricas Positivas Definidas (SPD - *Symmetric Positive Definite*), onde métricas de Riemann são apropriadas para medir a distância entre as matrizes. Um algoritmo que calcula a distância entre matrizes SPD no contexto de ICM-IM, proposto por [Barachant et al. 2011], é o Mínima Distância para a Média de Riemann (do inglês *Minimum Distance to Riemann Mean* - MDRM).

Segundo [Lotte et al. 2018] o algoritmo MDRM dispensa parametrizações complexas, simplificando o processamento ao mesmo tempo que mantém uma boa capacidade de generalização. Além de ser livre de parâmetros, o MDRM é robusto a ruídos inerentes dos sinais de EEG, invariante a transformações lineares e aplicável a diferentes paradigmas ICM, como a IM e a potenciais relacionadas a eventos. Ademais, a interpolação em geodésicas na variedade das matrizes SPD evita o "efeito de inchaço" presente na interpolação euclidiana, o que preserva a estrutura geométrica dos dados resultando em modelos mais robustos e precisos.

Os trabalhos de [Tang et al. 2021], [de Souza Alves et al. 2022] e [Racz et al. 2024] e outros utilizam o algoritmo MDRM com sucesso em diversas aplicações de ICM baseadas em Imagética Motora (IM). No entanto, uma lacuna ainda não explorada, proposta neste estudo, é aplicar o MDRM aos sinais de EEG após um banco de filtros, decompondo os sinais em subbandas para captar variações de IM por faixa de frequência. A aplicação do MDRM a cada subbanda forma um vetor de características aumentado, que é então entregue ao algoritmo de classificação Máquina de Vetor de Suporte (do inglês *Support Vector Machine* - SVM), com ajuste de hiperparâmetros realizado através da otimização bayesiana. Esses modelos, quando combinados, proporcionam uma melhoria significativa na precisão de decodificação de imagética motora, assegurando um alto desempenho na classificação da IM.

Neste contexto, o método proposto neste trabalho visa aprimorar a decodificação de sinais de EEG de duas classes de imagética motora: mão esquerda e mão direita. O artigo é organizado da seguinte forma: Seção 2 são discutidos os conceitos fundamentais necessários para a compreensão da pesquisa; Seção 3 aborda os procedimentos utilizados; Seção 4 apresenta os resultados obtidos da pesquisa; e na Seção 5 é apresentado as conclusões do trabalho proposto.

2. FUNDAMENTAÇÃO TEÓRICA

Nesta seção, são apresentadas as etapas e algoritmos fundamentais do processamento de sinais de EEG por subbanda de uma interface cérebro-máquina baseada em imagética motora. Inicialmente, são descritas as etapas de pré-processamento, extração de características e a normalização das subbandas. Por fim, são abordados os algoritmos de classificação e otimização empregados na pesquisa.

2.1 Filtragem Temporal

Embora o EEG seja uma técnica de baixo custo e não invasiva, sua baixa relação sinal-ruído o torna sensível a vários tipos de artefatos, incluindo sinais ocasionados por contrações musculares, atividades cardíacas, movimentos oculares, suor, interferência da rede, dentre outros [Savenhago et al. 2022]. Como resultado, a capacidade de detectar e interpretar corretamente a atividade cerebral diminui, uma vez que os artefatos podem se misturar ao sinal de interesse.

Neste contexto, a imagética motora - caracterizada pela capacidade de imaginar ou simular mentalmente um movimento - por estar associada aos fenômenos de Des/Sincronização relacionadas a eventos (ERS/ERD, do inglês *Event Related (De)Synchronization*), captados nas bandas de frequência μ e β , permite que seja possível reduzir os artefatos presentes no sinal através da filtragem por subbanda [Neto et al. 2022]. Ademais, a decomposição dos sinais em subbandas de frequência, tem

se mostrado mais eficaz na classificação em comparação com abordagens de banda única [Vilas-Boas and Silva 2020].

Neste estudo, para realizar a filtragem dos sinais, utiliza-se um banco de filtros *Butterworth* de 5º ordem, onde cada um dos filtros é projetado para uma banda de frequência específica, permitindo-se uma sobreposição entre as frequências de 50% [Novi et al. 2007]. Onde seja $\mathbf{X}_i^\ell \in \mathbb{R}^{c \times s}$, respectivamente, a i -ésima janela de EEG filtrada na ℓ -ésima subbanda de frequência, contendo c canais de EEG e s amostras coletadas a taxa de amostragem F_s , em que $i = 1, 2, \dots, N_a + N_b$ e $\ell = 1, 2, \dots, N_s$. As quantidades N_a, N_b e N_s , representam, respectivamente, número de exemplos nas classes \mathcal{A} e \mathcal{B} e o número de subbandas de frequência.

2.2 Minimum Distance to Riemann Mean - MDRM por subbanda

O MDRM é um classificador baseado no algoritmo de Mínima Distância à Média (MDM - *Minimum Distance to Mean*), que aplica a métrica de distância em um espaço riemanniano, calculando a média geométrica das matrizes de covariância para cada classe na fase de treinamento. Para realizar a classificação basta calcular a distância de Riemann de uma matriz de teste para as matrizes médias [Barachant et al. 2011]. A classe é atribuída em função da menor distância de Riemann para a média. A Figura 1, esquematiza o funcionamento do classificador MDRM para um problema de duas classes, onde Ω representa a variedade de Riemann, im indica um teste não rotulado e M_A^* e M_B^* a média geométrica das classes.




Fig. 1: Esquemático do classificador MDRM para um problema de duas classes. Fonte: Adaptado de [Lotte et al. 2018].

A aplicação do método por subbanda baseia-se em realizar o procedimento para cada uma das ℓ subbandas de frequência. Primeiramente, é necessário obter as matrizes de covariância a partir dos sinais de EEG filtrados por subbanda. Seja \mathbf{X}_i^ℓ a matriz contendo os sinais de EEG filtrados, a matriz de covariância correspondente é expressa na Eq. 1,

$$\mathbf{C}_i^\ell = \frac{1}{s} \mathbf{X}_i^\ell (\mathbf{X}_i^\ell)^T \quad (1)$$

em que $(.)^T$ representa a operação de transposição matricial.

A distância ao quadrado de Riemann entre duas matrizes de covariância é definida conforme a Eq. 2,

$$d_R^2(\mathbf{C}_1^\ell, \mathbf{C}_2^\ell) = \|\log((\mathbf{C}_1^\ell)^{-1} \mathbf{C}_2^\ell)\|_F^2 = \sum_{k=1}^c \log^2(\lambda_k), \quad (2)$$

onde $\|\cdot\|_F$ é a norma de *Frobenius*, λ_k é definido como o k -ésimo autovalor de $(\mathbf{C}_1^\ell)^{-1} \mathbf{C}_2^\ell$ e c é a ordem das matrizes simétricas positivas definidas (SPD do inglês *Symmetric Positive Definite*). A matriz

correspondente a média geométrica entre as matrizes de covariância por subbanda para cada classe é especificada segundo a Eq. 3,

$$\mathbf{M}_\rho^{\ell*} = \arg \min_{\mathbf{M}_{\rho,i}^\ell \in \mathbf{C}(n)} \sum_{i=1}^{N_\rho} d_R^2(\mathbf{C}_i^\ell, \mathbf{M}_{\rho,i}^\ell) \quad (3)$$

A matriz $\mathbf{M}_\rho^{\ell*}$ corresponde a média geométrica para a classe indicada por $\rho \in [a, b]$ para a subbanda ℓ . Logo para cada subbanda tem-se duas matrizes, uma para cada classe.

2.3 Normalização das subbandas

O algoritmo MDRM retorna as distâncias de Riemann da matriz de teste em relação as duas matrizes médias referentes a cada classe. Assim, com o objetivo de reduzir a dimensionalidade dos dados, as distâncias podem ser normalizadas para o intervalo entre -1 e $+1$, conforme a Eq. 4,

$$\bar{d}_R(\mathbf{C}_i^\ell) = \frac{d_R(\mathbf{C}_i^\ell, \mathbf{M}_a^\ell) - d_R(\mathbf{C}_i^\ell, \mathbf{M}_b^\ell)}{d_R(\mathbf{C}_i^\ell, \mathbf{M}_a^\ell) + d_R(\mathbf{C}_i^\ell, \mathbf{M}_b^\ell)}, \quad (4)$$

em que $\ell = [1, 2, \dots, N_s]$.

Cada distância normalizada na ℓ -ésima subbanda, é utilizada para compor o vetor de características \mathbf{v}_i , como apresentado na Eq. 5

$$\mathbf{v}_i = [\bar{d}_R(\mathbf{C}_i^1), \bar{d}_R(\mathbf{C}_i^2), \dots, \bar{d}_R(\mathbf{C}_i^{N_s})]^T \quad (5)$$

2.4 Classificação via *Support Vector Machine* -SVM

O algoritmo SVM é amplamente empregado na classificação em aplicações de ICMs [HALTAŞ et al. 2019], onde seu objetivo principal é determinar o hiperplano que melhor separa as classes de dados no espaço de características. Entre os principais hiperparâmetros desse algoritmo, destaca-se o *Kernel*, responsável por transformar os dados de entrada para um espaço de características de dimensão superior e o parâmetro C , que controla o equilíbrio entre ajustar o modelo aos dados disponíveis para treinamento.

A avaliação do seu desempenho é realizada utilizando a métrica de acurácia, que quantifica a taxa de acerto na classificação. A acurácia é calculada dividindo-se o números de exemplos classificados corretamente, ρ_r , pelo número total de ensaios realizados, ρ_T , durante um experimento [Vilas-Boas and Silva 2020]. A mesma é expressa em termos de porcentagem e calculada conforme demonstra a Eq. 6:

$$Acc(\%) = \frac{\rho_r}{\rho_T} \times 100 \quad (6)$$

A acurácia também é utilizada no processo de otimização, entretanto é interpretada em relação á taxa de erro de classificação, descrito na Eq. 7:

$$Erro = 1 - \frac{\rho_r}{\rho_T} \quad (7)$$

2.5 Otimização Bayesiana

Nos algoritmos complexos de processamento e classificação de sinais de EEG, ajustar os hiperparâmetros é uma tarefa desafiadora devido à alta dimensionalidade do espaço de configuração [Feurer and

Hutter 2019]. Além disso, as características inter e intra-sujeitos exigem ajustes individualizados de múltiplos hiperparâmetros, aumentando ainda mais a complexidade do processamento de dados [Saha and Baumert 2020]. A busca por um ajuste automatizado que encontre a combinação ideal para minimizar erros de classificação levou ao uso de métodos bayesianos, conhecidos por sua eficiência na otimização desses parâmetros [Thenmozhi and Helen 2022]

A otimização bayesiana utiliza uma abordagem probabilística que busca encontrar os extremos de uma função objetivo, baseando-se em um modelo que assume uma distribuição gaussiana multivariada dos valores da função [Varoquaux et al. 2024]. Esse modelo é usado para aproximar a função objetivo $g(h)$, representada na Eq. 8, e selecionar os parâmetros mais promissores dentro de um espaço de busca H , ao aproveitar resultados de tentativas anteriores de modo a minimizar o número de testes necessários, tornando o processo mais eficiente e direcionado.

$$h^* = \arg \max_{h \in H} g(h) \quad (8)$$

Neste trabalho o espaço de busca usado para determinar a combinação ótima dos hiperparâmetros é apresentado na Tabela I, onde f_l e f_h representam, respectivamente os delimitadores inicial e final

Tabela I: Configuração do espaço de busca

Hiperparâmetro	Espaço de busca
<i>Kernel</i>	{ <i>linear</i> , <i>rbf</i> , <i>poly</i> }
<i>C</i>	{ 0.255, 10, 10 ² , 10 ³ }
f_l , em Hz	{ 4,...,8 }
f_h , em Hz	{ 30,..., 35 }
N_s	{ 1, 2, ..., 9, 10 }

da região de buscas na frequência do sinal de EEG, N_s é o número de subbandas e *Kernel* e *C* são os parâmetros do classificador SVM.

O espaço de busca foi delimitado de modo a revelar características dos sinais EEG e otimizar a performance do classificador SVM. O parâmetro *Kernel* foi incluído pela sua capacidade de ajustar o modelo a diferentes distribuições de dados, desde relações lineares até não lineares. Da mesma forma, o parâmetro de regularização *C* é essencial para equilibrar a maximização da margem de separação e a minimização de erros de classificação, permitindo o controle da complexidade do modelo [Boas et al. 2021]. As frequências f_l e f_h foram selecionadas de modo a abranger as frequências μ e β , delimitando a bandas de frequências essenciais para a decodificação de IM. O número de subbandas N_s , com sobreposição de 50% permite explorar diferentes faixas de frequência, capturando variações sutis nos sinais de EEG que otimizam a análise das características relevantes.

3. METODOLOGIA

A metodologia deste estudo concentra-se no ajuste ótimo dos hiperparâmetros associados aos processos essenciais para o funcionamento eficaz de uma ICM-IM. A Figura 2 ilustra o pipeline de processamento dos sinais de EEG utilizada na pesquisa, destacando o espaço de busca de hiperparâmetros explorado com o intuito de aprimorar a precisão e robustez do modelo.

O método proposto, observada na Figura 2, envolve a utilização de segmentos de sinais de EEG, filtrados temporalmente em N_s subbandas com sobreposição de 50%. Esses sinais são transformados em matrizes de covariância SPD, que são então fornecidas ao classificador MDM. O MDM aplica a distância mínima a média de riemann para calcular suas distâncias, as quais são normalizadas para formar um vetor de características. Este vetor é, então, utilizado pelo classificador SVM para a decodificação de IM.

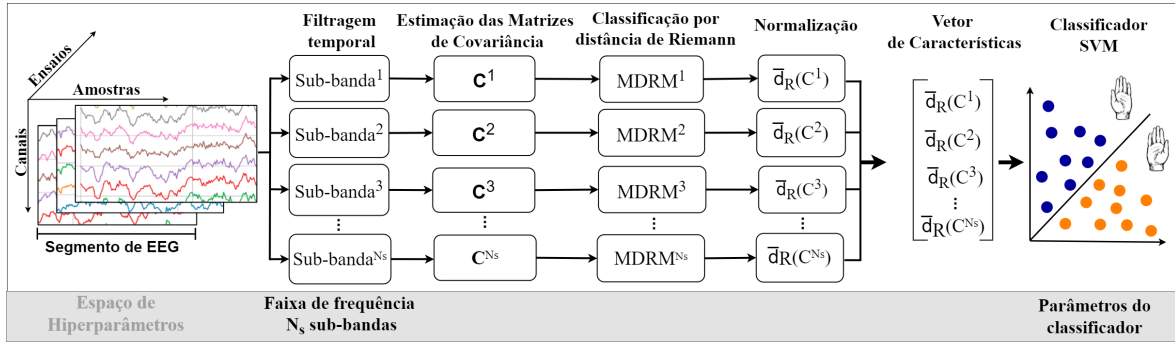


Fig. 2: Pipeline do MDRM por subbandas. Fonte: Autor

3.1 Conjunto de dados

O estudo utiliza o subconjunto 2a de dados EEG obtido no repositório público da IV Competição Internacional de Sistemas ICM [Brunner et al. 2008], composto por registros de 9 sujeitos submetidos a a quatro tarefas distintas de IM: a imagética da mão esquerda (Classe 1), da mão direita (Classe 2), dos pés (Classe 3) e da língua (Classe 4). Os dados são disponibilizados em duas sessões, cada uma contendo 144 exemplos, ou tentativas, para cada classe, registrados com $c = 22$ eletrodos (canais) a uma taxa de amostragem de $F_s = 250$ Hz.

O registro dos sinais de EEG é realizado conforme protocolo de experimentação descrito em [Brunner et al. 2008]. Para os experimentos conduzidos neste trabalho, são utilizados apenas as classes 1 e 2, resultando em 288 exemplos no total. Esse conjunto é dividido em 144 tentativas para treinamento e 144 para teste, com 72 exemplos por classe. Com base no protocolo experimental, é selecionada um segmento de sinal de 2,0 segundos, iniciada 0.5 segundos após a apresentação da dica visual. Esse procedimento seleciona o período de tempo relevante relacionado à imagética motora, conforme [Silva 2017]

3.2 Ambiente computacional

A implementação das etapas de processamento e classificação assim como a otimização dos hiperparâmetros relacionados a cada uma das fases, é realizada em nuvem através do ambiente de desenvolvimento integrado *Google Colaboratory* [Bisong 2019] mediante o uso de linguagem em *Python*¹ através das bibliotecas *Numpy*², *Scikit-learn*³, *Scikit-optimize*⁴ e *pyRiemann*⁵.

A otimização bayesiana foi implementada por meio da função *gp_minimize* da biblioteca *Scikit-optimize*, a qual é empregada para encontrar o mínimo da função objetivo. Os parâmetros desta função são configuradas da seguinte forma:

- **Função objetivo a ser minimizada:** contém a referência ao *pipeline* de execução, ao espaço de busca e retorna o valor objetivo encontrado em cada interação;
- **Dimensões:** recebe o espaço de busca definido na Tabela I;
- **Número de interações:** é definido 30 interações para cada sujeito;
- **Número de avaliações:** é definida a execução de 10 interações aleatórias para avaliar o comportamento da função objetivo antes de iniciar o processo de otimização.

¹*Python* v.3.10.12 - <https://www.python.org>

²*Numpy* v. 1.26.4 - <https://numpy.org/>

³*Scikit-learn* v.1.3.2 - <https://scikit-learn.org>

⁴*Scikit-optimize* v. 0.10.2 - <https://pypi.org/project/scikit-optimize/>

⁵*pyRiemann* v.0.6 - <https://pypi.org/project/pyriemann/>

4. RESULTADOS

Os resultados de classificação, expresso em termos de acurácia, estão apresentados na Tabela II. A análise é realizada em dois cenários: no Caso 1, os dados de treinamento são utilizados para o ajuste do modelo, enquanto os dados de teste são utilizados para validação do modelo; já no Caso 2, invertemos essa configuração, utilizando os dados de treinamento para validação e os dados de teste para treinamento.

Os resultados são comparados com a referência [Congedo et al. 2013], que introduz um novo método de classificação de ICMS baseados em geometria riemanniana. No estudo, [Congedo et al. 2013] propõe o uso do classificador MDM através do algoritmo MDRM de modo a criar uma estrutura de classificação eficiente e de alta generalização, permitindo um desempenho robusto em ambientes reais, uma vez que dispensa treinamentos extensivos e adapta-se rapidamente a diferentes usuários e sessões. Essa proposta é considerada uma referência para novas gerações de ICMS pela sua aplicabilidade em diversos paradigmas ICMS. Ao compará-lo com o método proposto neste estudo, nota-se que para ambos os Casos, e para todos os sujeitos, os resultados obtidos apresentam valores de acurácia superiores aos da referência. Para os sujeitos 3, 5 e 7 são observados os maiores incrementos na taxa de classificação correta dos sinais de EEG.

A análise das médias das acurácias observadas em ambos os casos revelou um aumento de 80.25% para 86.11% no Caso 1, e de 72.61% para 83.87% no Caso 2. Em termos de desvio padrão observa-se, também, ganhos de desempenho, reduzindo-se o espalhamento de 13.78 para 11.91 no Caso 1, e de 14.04 para 10.95 no Caso 2.

Tabela II: Acurácia de Classificação

Sujeito	Caso 1		Caso 2	
	Referência	Proposta	Referência	Proposta
1	93.75%	95.14%	74.31%	90.28%
2	63.19%	63.89%	50.00%	65.97%
3	94.44%	98.61%	88.89%	94.44%
4	75.00%	78.47%	65.28%	71.53%
5	63.19%	88.19%	63.89%	88.89%
6	71.53%	72.92%	61.81%	73.61%
7	72.92%	88.19%	73.61%	88.89%
8	96.53%	97.22%	94.44%	97.22%
9	91.67%	92.36%	81.25%	84.03%
Média	80.25% ± 13.78	86.11% ± 11.91	72.61% ± 14.04	83.87% ± 10.95

As Tabelas III e IV apresentam os hiperparâmetros selecionados pela otimização Bayesiana dado o espaço de busca definido na seção 3.2. É possível observar a capacidade da abordagem adotada de se adaptar as características intra e inter sujeito de modo a identificar os parâmetros que ocasionem na classificação mais eficiente.

Tabela III: Hiperparâmetros selecionados por sujeito - Caso 1

Hiperparâmetros	Sujeitos								
	1	2	3	4	5	6	7	8	9
f_l , em Hz	4	6	6	8	4	6	4	8	8
f_h , em Hz	33	30	35	34	35	31	30	35	31
kernel	<i>linear</i>	<i>linear</i>	<i>poly</i>	<i>rbf</i>	<i>linear</i>	<i>linear</i>	<i>rbf</i>	<i>rbf</i>	<i>linear</i>
C	0.255	100	10	100	10	100	100	0.255	10
N_s	4	5	8	3	9	6	5	6	3

Tabela IV: Hiperparâmetros selecionados por sujeito - Caso 2

Hiperparâmetros	Sujeitos								
	1	2	3	4	5	6	7	8	9
f_l , em Hz	4	8	4	8	4	4	4	7	4
f_h , em Hz	33	30	33	34	35	30	31	34	31
kernel	poly	poly	linear	rbf	poly	rbf	linear	rbf	linear
C	1000	10	10	1000	100	1000	100	0.255	1000
N_s	9	8	10	8	9	4	10	9	1

5. CONSIDERAÇÕES FINAIS

Este trabalho apresenta uma abordagem aprimorada para o processamento de sinais de EEG em aplicações de ICM baseadas em imagética motora, focando na classificação de sinais de duas classes: imagética da mão esquerda e da mão direita. Propomos uma representação dos sinais de EEG filtrados temporalmente, utilizando matrizes de covariância simétricas definidas positivas. Para calcular a média geométrica entre essas matrizes e determinar a menor distância de Riemann entre elas, aplicamos o algoritmo MDRM. Este processo resulta em duas matrizes médias, cada uma correspondente a uma classe de imagética. As distâncias obtidas são normalizadas para formar um vetor de características, que é então utilizado pelo classificador SVM na etapa final de classificação. Adicionalmente, é implementado a otimização bayesiana para selecionar os hiperparâmetros mais adequados para cada sujeito, buscando assim aprimorar a eficácia do sistema.

Os resultados evidenciam que a aplicação do método proposto proporcionou um aumento nas taxas de classificação correta para todos os sujeitos e casos estudados. Em particular, as médias e os desvios padrões das acurácias de classificação obtidas foram de 86,11% e 11,91 para o Caso 1, e 83,87% e 10,95 para o Caso 2. Esses resultados indicam uma melhoria substancial em comparação com a abordagem apresentada por [Congedo et al. 2013]. A eficácia e robustez da abordagem refletem que o método não só melhora o desempenho de classificação, mas também destaca a sua capacidade de lidar com variabilidades individuais nos sinais de EEG, corroborando sua aplicação prática em cenários de ICM-IM.

Para pesquisas futuras, objetiva-se aprimorar as ferramentas utilizadas na abordagem, com ênfase no processamento por subbandas e na classificação. Uma das melhorias propostas incluirá a criação de subbandas com comprimentos variados durante uma mesma interação. Ademais, planeja-se expandir o espaço de busca dos hiperparâmetros ao incorporar novos modelos de classificação e seus parâmetros próprios, utilizando novos conjuntos de dados que contenham uma quantidade mais expressiva de ensaios e sujeitos, visando testar e validar o desempenho do sistema em um novo cenário.

REFERÊNCIAS

- ALTINDIŞ, F. AND YILMAZ, B. Sliding window and filterbank utilization on riemannian geometry. In *2022 International Conference on INnovations in Intelligent SysTems and Applications (INISTA)*. IEEE, pp. 1–5, 2022.
- BARACHANT, A., BONNET, S., CONGEDO, M., AND JUTTEN, C. Multiclass brain–computer interface classification by riemannian geometry. *IEEE Transactions on Biomedical Engineering* 59 (4): 920–928, 2011.
- BISONG, E. pp. 59–64. In , *Google Colaboratory*. Apress, Berkeley, CA, pp. 59–64, 2019.
- BOAS, V., MENDES, V., ET AL. Autobci: interface cérebro-máquina com configuração hiperparamétrica automatizada, 2021.
- BRUNNER, C., LEEB, R., MÜLLER-PUTZ, G., SCHLÖGL, A., AND PFURTSCHELLER, G. Bci competition 2008–graz data set a. *Institute for knowledge discovery (laboratory of brain-computer interfaces), Graz University of Technology* vol. 16, pp. 1–6, 2008.
- BRUNNER, C., LEEB, R., MÜLLER-PUTZ, G. R., SCHLÖOGL, A., AND PFURTSCHELLER, G. BCI competition 2008 – graz data set a. *Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces)* vol. 16, 2008.
- CONGEDO, M., BARACHANT, A., AND ANDREEV, A. A new generation of brain-computer interface based on riemannian geometry. *arXiv preprint arXiv:1310.8115*, 2013.

- DE SOUZA ALVES, D. R., TEIXEIRA, O. N., AND SILVA, C. D. Feature weighting on eeg signal by artificial bee colony for classification of motor imaginary tasks. In *International Conference on Sensing and Imaging*. Springer, pp. 301–310, 2022.
- FEURER, M. AND HUTTER, F. Hyperparameter optimization. *Automated machine learning: Methods, systems, challenges*, 2019.
- HALTAŞ, K., ERGÜZEN, A., AND ERDAL, E. Classification methods in eeg based motor imagery bci systems. In *2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*. pp. 1–5, 2019.
- HUANG, Z., GUO, J., ZHENG, W., WU, Y., LIN, Z., AND ZHENG, H. A calibration-free approach to implementing p300-based brain-computer interface. *Cognitive Computation* 14 (2): 887–899, 2022.
- KANG, J.-S., KAVURI, S., AND LEE, M. Adaptive eeg noise filtering for coherence analysis. In *2014 International Winter Workshop on Brain-Computer Interface (BCI)*. pp. 1–4, 2014.
- LOTTE, F., BOUGRAIN, L., CICHOCKI, A., CLERC, M., CONGEDO, M., RAKOTOMAMONJY, A., AND YGER, F. A review of classification algorithms for eeg-based brain-computer interfaces: a 10 year update. *Journal of neural engineering* 15 (3): 031005, 2018.
- LUCK, S. Quantifying erp amplitudes and latencies. *An introduction to the event-related potential technique*, 2014.
- MÜLLER-PUTZ, G. R., OFNER, P., SCHWARZ, A., PEREIRA, J., PINEGGER, A., DIAS, C. L., HEHENBERGER, L., KOBLE, R., AND SBURLEA, A. I. Towards non-invasive eeg-based arm/hand-control in users with spinal cord injury. In *2017 5th International Winter Conference on Brain-Computer Interface (BCI)*. IEEE, pp. 63–65, 2017.
- NETO, F. F. D. S., JORGE, V. D. S., AND DA SILVA, C. D. Comparison of performance of scenarios with one and three brain-machine interfaces applied. In *Encontro Nacional de Inteligência Artificial e Computacional (ENIAC)*. SBC, pp. 198–209, 2022.
- NICOLAS-ALONSO, L. F. AND GOMEZ-GIL, J. Brain computer interfaces, a review. *sensors* 12 (2): 1211–1279, 2012.
- NOVI, Q., GUAN, C., DAT, T., AND XUE, P. Sub-band common spatial pattern (sbcs) for brain-computer interface. *Proceedings of the 3rd International IEEE EMBS Conference on Neural Engineering*, 06, 2007.
- RACZ, F. S., KUMAR, S., KAPOSZTA, Z., ALAWIEH, H., LIU, D. H., LIU, R., CZOCH, A., MUKLI, P., AND MILLÁN, J. D. R. Combining detrended cross-correlation analysis with riemannian geometry-based classification for improved brain-computer interface performance. *Frontiers in Neuroscience* vol. 18, pp. 1271831, 2024.
- SAHA, S. AND BAUMERT, M. Intra-and inter-subject variability in eeg-based sensorimotor brain computer interface: a review. *Frontiers in computational neuroscience* vol. 13, pp. 87, 2020.
- SAVENHAGO, R. L., DE ÁVILA, P. M., AND ORTOLAN, R. L. Arquiteturas de redes neurais e suas aplicabilidades para classificação de sinais eeg para bci. *Revista Brasileira de Computação Aplicada* 14 (1): 55–69, 2022.
- SILVA, C. D. Processamento de sinais de eeg para classificação de tarefas motoras em sistemas de interface cérebro-máquina. *Orientador: Alexandre Trofino Neto*, 2017.
- TANG, X., LI, X., LI, W., HAO, B., XIE, Y., AND DANG, X. Transfer learning: Rotation alignment with riemannian mean for brain-computer interfaces and wheelchair control. *IEEE Transactions on Cognitive and Developmental Systems* 15 (2): 487–498, 2021.
- THENMOZHI, T. AND HELEN, R. Feature selection using extreme gradient boosting bayesian optimization to upgrade the classification performance of motor imagery signals for bci. *Journal of Neuroscience Methods* vol. 366, pp. 109425, 2022.
- VAROQUAUX, G., SELF-CONSTRUCT, E., DE BUYL, P., MILLMAN, J., INGOLD, G.-L., GOULLART, E., VAN DER WALT, S., HARTMANN, M., JĘDRZEJEWSKI-SZMEK, Z., VAHTRAS, O., ROUGIER, N. P., GOMMERS, R., HABERLAND, M., UCHIDA, A., VIRTANEN, P., COMBELLES, C., PETTIAUX, N., BARNOWSKI, R., KNIGHT, V., AESPAZE, CIMRMAN, R., ROY, P., VAROQUAUX, N., DEN BOSSCHE, J. V., PINTÉ, D., MASARONE, N., TELENCZUK, B., RIEHL, M., AND CAGLAYAN, O. *scipy-lectures/scientific-python-lectures: Release 2024.1*, 2024.
- VILAS-BOAS, V. M. AND SILVA, C. D. Configuração automática de hiperparâmetros em sistemas mi-bci de sub-bandas. In *Anais do XXXVIII Simpósio Brasileiro de Telecomunicações e Processamento de Sinais - SBrT 2020*. Florianópolis, SC, 2020.