

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

Leilane de Jesus dos Anjos
PPG em Engenharia Elétrica
Universidade Federal do ABC
Santo André, Brasil
leilane.anjos@ufabc.edu.br

Cleison Daniel Silva
PPG em Computação Aplicada
Universidade Federal do Pará
Tucuruí, Brasil
cleison@ufpa.br

Angello Gabriel Alves Gonçalves
Faculdade de Engenharia Elétrica
Universidade Federal do Pará
Tucuruí, Brasil
angello.goncalves@tucurui.ufpa.br

Abstract—Brain-Computer Interface systems based on Motor Imagery decode the user's motor intentions from electroencephalography (EEG) signals, converting them into control commands for devices external to the human body. This paper proposes an enhanced approach for classifying EEG signals related to four motor imagery classes evaluated across binary combinations. The methodology employs symmetric positive definite covariance matrices extracted after applying a filter bank with overlapping sub-bands. Feature extraction is based on the Riemannian distance between mean matrices computed using the MDRM algorithm; the resulting values are normalized and used as input to a Support Vector Machine (SVM) classifier. Bayesian optimization is applied to fine-tune the system's hyperparameters automatically. Experimental results show superior performance compared to the reference method in the literature, confirming the effectiveness of the proposed approach in adapting to intra- and inter-subject variability in two evaluated scenarios.

Index Terms—Riemann Geometry, Bayesian Optimization, Brain-Computer Interface.

I. 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 [1], [2].

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 [3]. Este estudo, no entanto, enfatiza os ritmos sensório-motores (SMRs), que são predominantemente detectados nas faixas de frequência μ {8 – 13 Hz} e β {13 – 30 Hz}. Os SMRs podem ser modulados pela execução ou Imagética Motora (IM) e medidos por técnicas de eletroencefalografia (EEG) [4]. Embora estas oscilações estejam tipicamente concentradas nas bandas μ e β , este trabalho investiga uma faixa estendida (4-35 Hz) para assim explorar possíveis componentes informativas que possam estar de fora das faixas tradicionais.

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 [5], é essencial que os sistemas ICM

continuem a aprimorar a precisão na decodificação das tarefas de IM executadas pelo indivíduo.

Sabe-se que o desempenho dos sistemas de Interface Cérebro-Máquina baseados em IM (ICM-IM) pode ser aprimorado ao considerar configurações específicas para cada usuário [6]. Dadas as características inter e intra sujeitos, a calibração nos sistemas de ICM-IM exige um ajuste individual com relação aos parâmetros que podem ser associados às etapas de processamento e classificação [7].

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. O algoritmo Minimum Distance to Riemann Mean (MDRM) calcula a distância entre matrizes SPD no contexto de ICM-IM, conforme proposto por [8].

Segundo [9], o algoritmo MDRM evita parametrizações complexas, simplificando o processamento e mantendo 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 os potenciais relacionados 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 [10], [11] e [12] e outros utilizam o algoritmo MDRM com sucesso em diversas aplicações de ICM baseadas em IM. Uma lacuna ainda não explorada, proposta neste estudo, consiste em aplicar o MDRM aos sinais de EEG após decomposição por banco de filtros, a fim de captar variações de IM em diferentes sub-bandas de frequência. A aplicação do MDRM a cada sub-banda 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 IM, assegurando um alto

desempenho na classificação da IM.

Diante disso, neste artigo, é proposto um método que visa aprimorar a decodificação de sinais de EEG das 4 classes de IM: mão esquerda, mão direita, pés e língua combinadas em pares para tarefas de classificação binária. O artigo é organizado da seguinte forma: Seção II são discutidos os conceitos fundamentais necessários para a compreensão da pesquisa; Seção III aborda os procedimentos utilizados; Seção IV apresenta os resultados obtidos da pesquisa; e na Seção V são apresentadas as conclusões do trabalho proposto.

II. FUNDAMENTAÇÃO TEÓRICA

A. Filtragem Temporal

A coleta de sinais via Eletroencefalografia (EEG) é uma técnica de baixo custo e não invasiva, no entanto, os sinais de EEG apresentam baixa relação sinal-ruído, o que os torna sensíveis a vários tipos de artefatos, incluindo sinais ocasionados por contrações musculares, atividades cardíacas, movimentos oculares, suor, interferência da rede, dentre outros [13]. 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 IM - caracterizada pela capacidade de imaginar ou simular mentalmente um movimento - por estar associada aos fenômenos de Des/Sincronização relacionados 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 sub-banda [14]. Ademais, a decomposição dos sinais em sub-bandas de frequência tem-se mostrado mais eficaz na classificação em comparação com abordagens de banda única [15].

A filtragem dos sinais de EEG é realizada por um banco de filtros lineares do tipo *Butterworth* de 5º ordem. Cada um dos filtros é projetado para uma banda de frequência específica, admitindo-se sobreposição de 50% entre as bandas de frequência [16]. Considere que os sinais de EEG coletados pertencem a duas categorias, denominadas de classes $\mathcal{A}$ e $\mathcal{B}$. Seja a matriz $\mathbf{X}_i^\ell \in \mathbb{R}^{N_e \times N_t}$, represente a i -ésima janela de sinais de EEG após a filtragem na ℓ -ésima sub-banda de frequência. Os sinais $\mathbf{X}_i^\ell$ contém N_e eletrodos de EEG cada um com N_t 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, o número de exemplos na classe $\mathcal{A}$, na classe $\mathcal{B}$ e o número de sub-bandas de frequência.

B. Minimum Distance to Riemann Mean - MDRM por sub-banda

O MDRM é um algoritmo de classificação baseado na Mínima Distância à Média (MDM - *Minimum Distance to Mean*). Na fase de treinamento, o MDRM utiliza a distância de Riemann para calcular a média geométrica das matrizes de covariância dos sinais de EEG para as classes $\mathcal{A}$ e $\mathcal{B}$. Assim a classificação de uma matriz de covariância de teste, é realizada ao verificar-se a menor distância de Riemann para

as matrizes médias das classes [8]. A Figura 1 esquematiza o funcionamento do classificador MDRM para um problema de duas classes, em que Ω representa o espaço de matrizes de covariância, im representa uma matriz de covariância de teste, e as matrizes M_A^* e M_B^* são as matrizes médias geométricas das classes $\mathcal{A}$ e $\mathcal{B}$, respectivamente.




Fig. 1. Esquemático do classificador MDRM para um problema de duas classes. Note que a linha preta representa a geodésica, menor distância no espaço de Riemann. Fonte: Adaptado de [17].

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

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

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

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

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

onde $\|\cdot\|_F$ é a norma de *Frobenius*, λ_k é definido como o k -ésimo autovalor de $(\mathbf{C}_1^\ell)^{-1} \mathbf{C}_2^\ell$.

A matriz correspondente a média geométrica entre as matrizes de covariância por sub-banda para cada classe é especificada segundo a Eq. 3,

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

a matriz $\mathbf{M}_\rho^{\ell*}$ corresponde a média geométrica para a classe indicada por $\rho \in \{a, b\}$ para a sub-banda ℓ . Logo para cada sub-banda tem-se duas matrizes ótimas $\mathbf{M}_a^{\ell*}$ e $\mathbf{M}_b^{\ell*}$.

C. Normalização das sub-bandas e vetor de features

Após o treinamento, o algoritmo MDRM retorna as distâncias de Riemann da matriz de covariância de teste em relação às duas matrizes médias referentes as classes, $\mathbf{M}_a^{\ell*}$ e

$\mathbf{M}_b^{\ell*}$. Assim, as duas distâncias são convertidas em um único valor entre -1 e $+1$ através da normalização definida na Eq. 4 conforme descrito em [29],

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

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

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

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

D. Classificação via SVM e Métrica de avaliação

O algoritmo *Support Vector Machine* - SVM é amplamente empregado na classificação em aplicações de ICMs [18]. O SVM determina o hiperplano que maximiza a margem de separação entre as classes de dados no espaço de *feature*. Entre os principais hiperparâmetros do SVM, destaca-se o *Kernel*: responsável por transformar os dados de entrada para um espaço de *feature* de dimensão superior; e o parâmetro de regularização, C : que controla o equilíbrio entre ajustar o modelo aos dados disponíveis para treinamento [27].

A avaliação do desempenho do SVM é realizada através da acurácia, que quantifica a taxa de acerto na classificação. A acurácia é calculada dividindo-se os números de exemplos classificados corretamente, ρ_c , pelo número total de exemplos disponíveis, ρ_T , durante o experimento [15]. A acurácia está expressa na Eq. 6,

$$Acc = \frac{\rho_c}{\rho_T}. \quad (6)$$

A taxa de erro de classificação, utilizado no processo de otimização dos hiperparâmetros, é obtido a partir da acurácia, conforme definido na Eq. 7:

$$Erro = 1 - Acc. \quad (7)$$

E. Otimização Bayesiana

Nos algoritmos complexos de processamento e classificação de imagética motora a partir de sinais de EEG, ajustar os hiperparâmetros é uma tarefa desafiadora devido à alta dimensionalidade do espaço de configuração do sistema ICM [28]. Além disso, as características inter e intra-sujeitos exigem ajustes individualizados de múltiplos hiperparâmetros, aumentando ainda mais a complexidade do processamento dos sinais [7]. A busca por um ajuste automatizado que encontre a combinação ideal para minimizar erros de classificação levou ao uso de métodos bayesianos, reconhecidos por sua eficiência na otimização quando não há função analítica definida [19].

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 [20]. Esse modelo é usado para aproximar uma função objetivo, $g(h)$, representada na Eq. 8, e selecionar os parâmetros mais promissores dentro de um espaço de busca $\mathcal{H}$, em que $h \in \mathcal{H}$. Ao aproveitar resultados de tentativas anteriores de modo a

minimizar o número de testes necessários, tornando o processo mais eficiente e direcionado. O problema de otimização é definido na Eq. 8,

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

Neste trabalho, os hiperparâmetros, h , e o espaço de busca, $\mathcal{H}$, definidos para determinar o ajuste ótimo dos hiperparâmetros são apresentados na Tabela I, em que f_l e

TABLE I
CONFIGURAÇÃO DO ESPAÇO DE BUSCA

Hiperparâmetro	Espaço de busca
<i>Kernel</i>	{ <i>linear</i> , <i>rbf</i> , <i>poly</i> }
C	{ 0.255, 10, 10^2 , 10^3 }
f_l	{ 4, 5, 6, 7, 8 }
f_h	{ 30, 31, 32, 33, 34, 35 }
N_s	{ 1, 2, ..., 9, 10 }

f_h representam, em ciclos por segundo, respectivamente os delimitadores inicial e final da região de buscas na frequência do sinal de EEG, N_s é o número de sub-bandas e *Kernel* e C são os parâmetros do classificador SVM.

O espaço de busca é delimitado de modo a revelar características dos sinais EEG e a otimizar a performance do classificador SVM. O parâmetro *Kernel* é 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 [21]. As frequências f_l e f_h são definidas de modo a conter as frequências μ e β , delimitando as bandas de frequências essenciais para a decodificação de IM. O número de sub-bandas 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.

F. Trabalhos Relacionados

No estudo de sinais de EEG, as matrizes de covariância são frequentemente utilizadas como uma forma robusta de extração de características. O trabalho de [30] introduziu um novo kernel baseado na geometria de Riemann para a classificação de imaginética motora (IM), demonstrando a superioridade dessa abordagem em relação à filtragem espacial tradicional. De maneira similar, o trabalho de [31] explora a parametrização de sinais de EEG, utilizando matrizes de kernel para a detecção de crises epiléticas.

A forma como as matrizes de covariância são tratadas é a principal conexão e o ponto de diferenciação entre esses estudos. Enquanto a abordagem de [30], aprofunda-se na geometria riemanniana para preservar a estrutura das matrizes, a metodologia de [31] adota uma abordagem mais tradicional, vetorizando as matrizes para usar como um vetor de atributos, sem explorar a sua geometria intrínseca.

Apesar dos avanços significativos e da exploração da geometria riemanniana na literatura, ainda existe uma lacuna na

integração de métodos que, além de preservar essa estrutura geométrica, realizem a otimização automática de parâmetros para adaptação individual. A presente proposta, portanto, busca preencher essa lacuna ao combinar a robustez da geometria riemanniana com a automatização da otimização bayesiana, resultando em um sistema mais adaptável e eficiente para uma BCI-IM.

III. METODOLOGIA

A metodologia deste estudo concentra-se no ajuste ótimo dos hiperparâmetros associados aos processos essenciais para o funcionamento eficaz de uma ICM-IM. O método proposto envolve a utilização de segmentos de sinais de EEG, filtrados temporalmente em N_s sub-bandas com sobreposição de 50%. Os segmentos de sinais filtrados são transformados em matrizes de covariância, que são então fornecidas ao algoritmo MDRM. Para cada sub-banda, o MDRM determina a distância de Riemann mínima entre a matriz de covariância e as matrizes médias de cada classe, as quais, em seguida, são normalizadas para formar um vetor de características aumentado. Este vetor é, então, utilizado pelo classificador SVM para a decodificação de IM.

A Figura 2 ilustra o *pipeline* de processamento dos sinais de EEG utilizado neste trabalho, com destaque para o espaço de busca de hiperparâmetros explorado com o intuito de aprimorar a precisão e robustez do sistema ICM-IM.

A. Conjunto de dados

Este trabalho utiliza o subconjunto 2a de dados EEG obtido no repositório público da IV Competição Internacional de Sistemas ICM [22], composto por registros de 9 sujeitos submetidos a quatro tarefas distintas de IM: a imagética da mão esquerda (*LH*), da mão direita (*RH*), dos pés (*FE*) e da língua (*TO*). Os dados são disponibilizados em duas sessões: sessão *T* e sessão *V*, cada uma contendo 144 exemplos por 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 [22]. Para os experimentos conduzidos neste trabalho, são utilizadas as 4 classes disponibilizadas em diferentes combinações binárias, a saber: $\{(LH, RH), (LH, FE), (LH, TO), (RH, FE), (RH, TO), (FE, TO)\}$.

Cada combinação binária contém 288 exemplos, sendo então divididos em 144 exemplos utilizados para treinamento e 144 para validação, com 72 exemplos por classe. Com base no protocolo experimental, é selecionado um segmento de sinal com duração de 2 segundos, iniciada no instante 0.5 segundo após a apresentação da dica visual. Esse procedimento, adotado conforme [23], determina o intervalo de tempo relacionado à IM.

Os resultados de classificação são expressos em termos de acurácia de classificação. A análise é conduzida em dois cenários: primeiramente, $T \rightarrow V$, os dados da sessão *T* são utilizados para o ajuste do modelo, enquanto os dados da sessão *V* são utilizados para teste; em seguida, altera-se a

ordem de utilização dos dados, $V \rightarrow T$, em que utiliza-se a sessão *V* para ajuste do modelo e a sessão *T* para teste.

B. 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* [25] 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 é 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 iterações para cada sujeito;
- **Número de avaliações:** é definida a execução de 10 iterações aleatórias para avaliar o comportamento da função objetivo antes de iniciar o processo de otimização.

IV. RESULTADOS

Os resultados alcançados ao se aplicar a metodologia são apresentados na Tabela II, e são comparáveis aos da referência [24], evidenciados na Tabela III. No estudo, [24] 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.

A análise comparativa entre os métodos permitiu evidenciar, a partir da acurácia, os efeitos da utilização da filtragem por sub-banda com sobreposição aliada à otimização bayesiana. Observa-se que, em ambos os cenários analisados, a média global apresentou valores com resultados superiores aos de referência para cada classificação binária. Esses resultados indicam que o método proposto foi capaz de lidar eficazmente com as variações intra e inter-sujeito, ajustando-se às particularidades individuais e, consequentemente, maximizando o desempenho do algoritmo.

De forma complementar, as Figuras 3 e 4 ilustram, respectivamente, as faixas de frequências médias por combinação binária e por sujeito para $T \rightarrow V$. Por sua vez, as Figuras 5 e 6 trazem os mesmos resultados para $V \rightarrow T$. Nessas

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/>




Fig. 2. Pipeline do MDRM por sub-bandas. Fonte: Autor.

TABLE II
RESULTADOS DA ACURÁCIA (Acc) DE CLASSIFICAÇÃO POR SUJEITO E POR COMBINAÇÃO BINÁRIA, EM PORCENTAGEM. FONTE: AUTOR.

Sujeito	$LH \times RH$		$LH \times FE$		$LH \times TO$		$RH \times FE$		$RH \times TO$		$FE \times TO$	
	$T \rightarrow V$	$V \rightarrow T$	$T \rightarrow V$	$V \rightarrow T$	$T \rightarrow V$	$V \rightarrow T$	$T \rightarrow V$	$V \rightarrow T$	$T \rightarrow V$	$V \rightarrow T$	$T \rightarrow V$	$V \rightarrow T$
S1	95.14	90.28	97.91	97.91	99.30	97.22	99.89	96.52	99.89	99.30	79.16	80.55
S2	63.89	65.97	85.41	81.25	73.61	74.30	86.11	85.41	75.00	76.38	81.94	87.50
S3	98.61	94.44	93.75	92.36	95.83	96.52	97.91	88.88	98.61	95.83	85.41	85.41
S4	78.47	71.53	78.47	75.00	77.77	73.61	61.11	50.00	63.88	55.55	77.08	78.47
S5	88.19	88.89	81.94	79.86	84.72	80.55	89.58	90.27	91.66	90.27	75.69	70.13
S6	72.92	73.61	76.38	79.16	69.44	75.69	72.91	77.08	68.75	65.97	82.63	63.88
S7	88.19	88.89	99.30	93.30	97.91	98.61	98.61	99.88	99.89	98.61	84.72	90.27
S8	97.22	97.22	93.05	86.11	86.11	95.13	89.58	93.05	91.66	93.75	85.41	93.05
S9	92.36	84.03	94.44	90.97	99.30	98.61	85.41	88.19	92.36	93.75	92.36	93.75
Média Global	86.11	83.87	88.96	86.21	87.10	87.80	86.79	85.47	86.85	85.49	82.71	82.55
Desvio Padrão	11.91	10.95	8.07	7.36	10.94	10.72	12.04	13.97	13.12	14.86	4.78	9.72

TABLE III
ACURÁCIA DE CLASSIFICAÇÃO BINÁRIA UTILIZANDO MDM COM ABORDAGEM DE [24] EM PORCENTAGEM

Sujeito	$LH \times RH$		$LH \times FE$		$LH \times TO$		$RH \times FE$		$RH \times TO$		$FE \times TO$	
	$T \rightarrow V$	$V \rightarrow T$	$T \rightarrow V$	$V \rightarrow T$	$T \rightarrow V$	$V \rightarrow T$	$T \rightarrow V$	$V \rightarrow T$	$T \rightarrow V$	$V \rightarrow T$	$T \rightarrow V$	$V \rightarrow T$
S1	93.75	74.31	96.53	94.44	98.61	95.14	97.22	92.36	99.31	98.61	70.14	79.86
S2	63.19	50.00	78.47	76.39	68.06	53.47	74.31	77.08	72.22	74.31	74.31	77.78
S3	94.44	88.89	89.58	82.64	86.81	92.36	95.14	85.42	97.92	94.44	66.67	81.25
S4	75.00	65.28	88.89	72.22	88.19	78.47	92.36	70.83	84.72	72.92	62.50	68.75
S5	63.19	63.89	73.61	65.28	64.58	72.22	72.22	66.67	70.14	72.22	70.14	59.03
S6	71.53	61.81	71.53	70.14	64.58	59.42	65.28	60.56	63.89	61.11	72.22	63.19
S7	72.92	73.61	91.67	87.50	88.89	87.50	90.97	87.50	85.42	87.50	78.47	80.56
S8	96.53	94.44	85.42	79.17	86.11	87.50	90.28	87.50	92.36	87.50	87.50	79.86
S9	91.67	81.25	93.06	88.19	97.22	96.81	72.22	83.33	81.94	80.58	90.28	88.89
Média Global	80.25	72.61	85.42	81.44	82.56	80.32	83.33	79.03	83.10	81.01	74.69	75.46
Desvio Padrão	13.78	14.04	8.88	11.06	13.38	15.68	12.12	10.87	12.41	12.03	9.23	9.68

visualizações, as barras horizontais simbolizam os intervalos médios entre f_l e f_h , ao passo que os pontos e barras de erro refletem os desvios padrão.

Ademais, nota-se nas Figuras 4 e 6 que, mesmo a faixa de busca para o parâmetro f_l esteja estabelecida entre 4-8 Hz e para f_h até 35 Hz, os desvios padrão podem, em certas situações, exceder esses limites. Esta extrapolação não sugere que os valores otimizados transgrediram o espaço de busca, mas que a dispersão estatística calculada entre as 6 combinações binárias gerou médias próximas aos extremos, com variâncias que de forma analítica ultrapassam os limites estabelecidos.

Para $T \rightarrow V$, o sujeito 5 exibiu uma variância que ultrapassou os limites inferior e superior, enquanto o sujeito 8 superou o limite superior e o sujeito 7, o inferior. Já para $V \rightarrow T$, observou-se uma extrapolação inferior nos sujeitos 1, 4, 6 e 9; superior para os sujeitos 3 e 7; e em ambas as direções para o sujeito 5. Estas descobertas evidenciam a variedade de configurações espectrais ótimas escolhidas pela otimização bayesiana ao longo das diversas tarefas, enfatizando a importância de checar a variância como um indicador de dispersão, e não como uma transgressão dos limites delimitados.

Os resultados evidenciam a capacidade da otimização

bayesiana em ajustar de forma dinâmica os hiperparâmetros físicos do modelo. Constatase que, as faixas de frequência, tanto por combinação quanto por sujeito, se concentram nas bandas μ e β . A configuração média dos parâmetros enfatiza a capacidade adaptativa da abordagem proposta, mantendo alto desempenho mesmo diante da inversão dos conjuntos de treinamento e teste, como ocorre em $V \rightarrow T$. Esta capacidade de adaptação contribui diretamente na robustez do sistema em aplicações práticas de ICMs.




Fig. 3. Faixas de frequência médias ótimas para cada combinação binária de classes para $T \rightarrow V$. Fonte: Autor.




Fig. 4. Faixas de frequência médias ótimas por sujeito para $T \rightarrow V$, obtidas a partir das 6 combinações binárias de classes. Fonte: Autor.

V. CONSIDERAÇÕES FINAIS

Este trabalho apresenta uma abordagem aprimorada para o processamento de sinais de EEG em aplicações de ICM baseadas em IM, com foco na classificação de quatro classes avaliadas em diferentes combinações binárias. É proposto uma representação dos sinais de EEG filtrados temporalmente, utilizando matrizes de covariância. 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




Fig. 5. Faixas de frequência médias ótimas para cada combinação binária de classes para $V \rightarrow T$. Fonte: Autor.




Fig. 6. Faixas de frequência médias ótimas por sujeito para $V \rightarrow T$, obtidas a partir das 6 combinações binárias de classes. Fonte: Autor.

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 os cenários estudados. Onde observa-se maior média global e menor desvio padrão em comparação com a abordagem apresentada por [24]. 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.

No entanto, é importante reconhecer que, para a aplicabilidade prática, a interpretabilidade dos modelos e a latência de processamento em tempo real são considerações cruciais. A complexidade do MDRM, aliada à otimização bayesiana, pode gerar modelos eficazes, mas o tempo de processamento para a calibração automática podem limitar sua aplicação em ambientes que exigem feedback imediato.

Para pesquisas futuras, objetiva-se aprimorar as ferramentas utilizadas na abordagem, com ênfase no processamento por

sub-bandas e na classificação. Uma das melhorias propostas incluirá a criação de sub-bandas 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.

REFERENCES

- [1] 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.
- [2] Luck, S. Quantifying erp amplitudes and latencies. An introduction to the event-related potential technique, 2014.
- [3] Altındış, 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.
- [4] Nicolas-Alonso, L. F. and Gomez-Gil, J. Brain computer interfaces, a review. *sensors* 12 (2): 1211–1279, 2012.
- [5] 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.
- [6] Müller-Putz, G. R., Ofner, P., Schwarz, A., Pereira, J., Pinegger, A., Dias, C. L., Hehenberger, L., Kobler, 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.
- [7] 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.
- [8] 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.
- [9] 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.
- [10] 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.
- [11] 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.
- [12] 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.
- [13] 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.
- [14] 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.
- [15] 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.
- [16] Novi, Q., Guan, C., Dat, T., and Xue, P. Sub-band common spatial pattern (sbcspp) for brain-computer interface. *Proceedings of the 3rd International IEEE EMBS Conference on Neural Engineering*, 06, 2007.
- [17] 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.
- [18] 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.
- [19] 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.
- [20] Varoquaux, G., Self-Construct, E., de Buyl, P., Millman, J., Ingold, G.-L., Gouillart, E., van der Walt, S., Hartmann, M., Jedrzejewski-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., Pinte, D., Masarone, N., Telenczuk, B., Riehl, M., and Caglayan, O. *scipy-lectures/scientific-python-lectures: Release 2024.1*, 2024.
- [21] Boas, V., Mendes, V., et al. Autobci: interface cérebro-máquina com configuração hiperparamétrica automatizada, 2021.
- [22] 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.
- [23] Silva, C. D. Processamento de sinais de eeg para classificação de tarefas motoras em sistemas de interface cérebro-máquina. Orientador: Alexandre Trofino Neto, 2017.
- [24] Congedo, M., Barachant, A., and Andreev, A. A new generation of brain-computer interface based on riemannian geometry. *arXiv preprint arXiv:1310.8115*, 2013.
- [25] Bisong, E. pp. 59–64. In , Google Colaboratory. Apress, Berkeley, CA, pp. 59–64, 2019.
- [26] Zhang, Y., Nam, C. S., Zhou, G., Jin, J., Wang, X., & Cichocki, A. (2019). Temporally Constrained Sparse Group Spatial Patterns for Motor Imagery BCI. *IEEE Transactions on Cybernetics*, 49(9), 3322–3332.
- [27] VALKENBORG, Dirk et al. Support vector machines. *American Journal of Orthodontics and Dentofacial Orthopedics*, v. 164, n. 5, p. 754–757, 2023.
- [28] Feurer, M. and Hutter, F. Hyperparameter optimization. *Automated machine learning: Methods, systems, challenges*, 2019.
- [29] F. Zhuo, B. Lv and F. Tang, "Time Window Optimization for Riemannian Geometry-based Motor Imagery EEG Classification," 2024 46th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Orlando, FL, USA, 2024, pp. 1-5, doi: 10.1109/EMBC53108.2024.10782640.
- [30] BARACHANT, Alexandre et al. Classification of covariance matrices using a Riemannian-based kernel for BCI applications. *Neurocomputing*, v. 112, p. 172–178, 2013.
- [31] BARBOSA, Paulo; BARRETO, Guilherme. Parametrização de sinais de EEG para diagnóstico de epilepsia usando matrizes de kernel. In: BASTOS FILHO, Carmelo José Albanez; SIQUEIRA, Hugo Valadares; FERREIRA, Danton Diego; BERTOL, Douglas Wildgrube; OLIVEIRA, Roberto Célio Limão de (Orgs.). Anais do 15º Congresso Brasileiro de Inteligência Computacional. Joinville, SC: SBIC, 2021. p. 1-8.