



**UNIVERSIDADE FEDERAL DO PARÁ
CAMPUS UNIVERSITÁRIO DE TUCURUÍ
FACULDADE DE ENGENHARIA DE COMPUTAÇÃO
CURSO DE BACHARELADO EM ENGENHARIA DE COMPUTAÇÃO**

DANILO DE SOUSA LOPES

**SISTEMAS DE INTERFACE CÉREBRO-MÁQUINA:
CLASSIFICAÇÃO DE IMAGÉTICA MOTORA VIA GEOMETRIA
DE RIEMANN COM OTIMIZAÇÃO BAYESIANA**

**Tucuruí
2023**



**UNIVERSIDADE FEDERAL DO PARÁ
CAMPUS UNIVERSITÁRIO DE TUCURUÍ
FACULDADE DE ENGENHARIA DE COMPUTAÇÃO
CURSO DE BACHARELADO EM ENGENHARIA DE COMPUTAÇÃO**

DANILO DE SOUSA LOPES

**SISTEMAS DE INTERFACE CÉREBRO-MÁQUINA:
CLASSIFICAÇÃO DE IMAGÉTICA MOTORA VIA GEOMETRIA
DE RIEMANN COM OTIMIZAÇÃO BAYESIANA**

Trabalho de Conclusão de Curso apresentado à Faculdade de Engenharia de Computação do Campus Universitário de Tucuruí, da Universidade Federal do Pará, como requisito parcial para obtenção do grau de Bacharel em Engenharia de Computação.

Orientador: Prof. Dr. Cleison Daniel Silva

**Tucuruí
2023**

Lopes, Danilo de Sousa

SISTEMAS DE INTERFACE CÉREBRO-MÁQUINA: CLASSIFICAÇÃO DE IMAGÉTICA MOTORA VIA GEOMETRIA DE RIEMANN COM OTIMIZAÇÃO BAYESIANA/ DANILO DE SOUSA LOPES. – Tucuruí, 2023.

17 p. : il. (algumas color.) ; 30 cm.

Orientador: Prof. Dr. Cleison Daniel Silva

Monografia – UNIVERSIDADE FEDERAL DO PARÁ

CAMPUS UNIVERSITÁRIO DE TUCURUÍ

CURSO DE BACHARELADO EM ENGENHARIA DE COMPUTAÇÃO, 2023.

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

DANILO DE SOUSA LOPES

**SISTEMAS DE INTERFACE CÉREBRO-MÁQUINA:
CLASSIFICAÇÃO DE IMAGÉTICA MOTORA VIA
GEOMETRIA DE RIEMANN COM OTIMIZAÇÃO
BAYESIANA**

Trabalho de Conclusão de Curso apresentado
à Faculdade de Engenharia de Computação do
Campus Universitário de Tucuruí, da Universi-
dade Federal do Pará, como requisito parcial
para obtenção do grau de Bacharel em Engenha-
ria de Computação.

Data da Defesa: 19 de Dezembro de 2023
Conceito:

Banca Examinadora

Prof. Dr. Cleison Daniel Silva

Faculdade de Engenharia Elétrica - UFPA
Orientador

Prof. Dr. Daniel da Conceição Pinheiro

Faculdade de Engenharia de Computação -
UFPA
Membro da Banca

Prof. Dr. Otávio Noura Teixeira

Faculdade de Engenharia de Computação -
UFPA
Membro da Banca

Tucuruí
2023

Este trabalho é dedicado à minha amada família, em especial aos meus sobrinhos Júlia e Álvaro, que tornaram meus dias cada vez mais belos e cheios de significado.

AGRADECIMENTOS

Agradeço primeiramente a Deus por ter me concedido saúde e sabedoria para lidar com todos os desafios ao longo dessa jornada.

À minha família, pelo carinho, compreensão e apoio incondicional, em especial aos meus tios e padrinhos Virgínia Corrêa Dias e José Maria Gonçalves Dias, pelo afeto e por todo o sacrifício diário em prol de nos oferecer conforto, moral e educação. Vocês sempre serão minhas fontes de força e motivação.

Ao meu orientador, Prof. Dr. Cleison Daniel Silva, pela disponibilidade, paciência e palavras de incentivo, bem como pelos ensinamentos imprescindíveis que levarei por toda a minha vida.

A todos os demais professores da UFPA que, de alguma forma, contribuíram para o meu desenvolvimento intelectual e acadêmico.

Aos amigos da graduação Rui da Silva Nascimento, Vinícius Louzada Valente e Brendo de Araújo Rodrigues, pela parceria e pelos diversos momentos memoráveis. Agradeço também aos demais alunos da FECOMP 2018, os quais tive o prazer de conviver durante este período.

A todas as pessoas que, direta ou indiretamente, contribuíram para que este objetivo fosse alcançado.

Por fim, à Universidade Federal do Pará - UFPA, por oferecer este fantástico curso, o qual é responsável por grande parte do profissional que sou hoje.

*“Os grandes sucessos vem de ter
a liberdade para falhar.”
(Mark Zuckerberg)*

Sistemas de Interface Cérebro-Máquina: Classificação de Imagética Motora via Geometria de Riemann com Otimização Bayesiana

Danilo de Sousa Lopes [0009–0003–5640–5533]¹ and Cleison Daniel
Silva [0000–0001–8280–2928]¹

¹Universidade Federal do Pará (UFPA) Rodovia BR 422 km 13 –
Canteiro de Obras UHE, Tucuruí, 68464-000, Pará, Brasil.

Contributing authors: danlopes.eng@gmail.com; cleison@ufpa.br;

Resumo

Neste estudo, é apresentada uma nova metodologia para aprimorar o desempenho de sistemas de Interface Cérebro-Máquina baseados em Imagética Motora. Utilizaram-se informações de diferentes regiões do espectro dos sinais de eletroencefalografia, representadas como matrizes de covariância ponderadas pelo janelamento de sub-bandas no espaço Riemanniano. Para classificar essas matrizes, foi empregado o algoritmo Distância Mínima à Média de Riemann. Os hiperparâmetro que influenciam a faixa de frequência de interesse, comprimento da sub-banda e taxa de sobreposição, são refinados por meio da Otimização Bayesiana, que proporcionou novos graus de liberdade de ajustes individuais. Para a fusão da classificação das matrizes, foi adotado o algoritmo *Light Gradient Boosting Machine*, baseado no método *Ensemble*, que assegura uma melhor precisão final do modelo e alto desempenho na classificação da Imagética Motora. Os experimentos foram conduzidos com o conjunto de dados IIa da IV Competição Internacional de Interface Cérebro-Máquina, e, apesar dos resultados superiores em apenas dois sujeitos, não foram observadas melhorias substanciais em relação à abordagem do estado da arte. Ainda assim, a metodologia é promissora e indica potencial para futuras otimizações e desenvolvimentos.

Keywords: Interface cérebro-máquina, Eletroencefalograma, Otimização Bayesiana, Geometria de Riemann

1 Introdução

Os sistemas de Interface Cérebro-Máquina (BCI, do inglês, *Brain-Computer Interface*) foram inicialmente propostos com o objetivo de criar uma forma alternativa de comunicação entre o cérebro e o ambiente externo, através da tradução de biopotenciais elétricos gerados pela atividade cerebral [1]. Em geral, tais sistemas permitem o envio de mensagens e comandos a dispositivos a partir da coleta, processamento e tradução de biopotenciais elétricos relativos à atividade neuronal [2]. As alterações na atividade cerebral provocadas de maneira voluntária ou involuntária com a execução de tarefas cognitivas específicas descrevem atividades cerebrais mensuráveis e interpretáveis por esses sistemas [3].

Em meio às formas de indução voluntária de biopotenciais elétricos em sistemas BCI, a Imagética Motora - MI (do inglês, *Motor Imaginary*) destaca-se como uma das mais utilizadas. O paradigma da MI é livre de estimulações externas e confere autonomia ao usuário para a modulação da própria atividade cerebral [2]. A modulação voluntária nesse contexto faz referência à geração de padrões de atividade cerebral que descrevem sua intenção motora a partir da imaginação do movimento de algum membro ligado ao Sistema Nervoso Periférico (SNP), como as mãos, pés ou língua, por exemplo [4].

A ideia por trás da MI assegura que a imaginação do movimento ativa áreas do cérebro responsáveis pela geração de movimentos reais, em específico a região sensorio-motora do córtex, que, dentre suas funções, controla o Sistema Neuromuscular, que inclui os membros periféricos do corpo humano [5]. Na prática, a execução de uma tarefa de MI específica altera a atividade rítmica do cérebro, e o fenômeno neurológico de Sincronização/Dessincronização relacionada a evento - ERD/ERS (do inglês, *Event Related (De)Synchronization*) pode ser mensurado por meio de técnicas de neuroimagem [6].

Existe uma quantidade significativa de técnicas de neuroimagem capazes de medir a oscilação das atividades elétricas cerebrais, tanto de forma invasiva quanto de forma não invasiva. A maioria dos sistemas BCI faz uso da técnica de eletroencefalografia (EEG), devido à sua eficácia, principalmente por suas vantagens intrínsecas, como a alta resolução temporal, a alta portabilidade, o custo relativamente baixo e o risco mínimo à integridade física dos usuários [1]. Esses sistemas exploram propriedades desses sinais para ressaltar características associadas a tarefas mentais desenvolvidas ao longo de experimentos. O reconhecimento dessas características é regularmente utilizado para a classificação e inferência da intenção do usuário [7].

No entanto, mesmo que o sinal de EEG possua uma resolução temporal em milésimos de segundos, ele é altamente suscetível a ruídos, que podem reduzir o desempenho e a precisão dos sistemas BCI na discriminação das tarefas de MI, o que afeta na confiabilidade do sistema. O desempenho dos sistemas BCI, no entanto, pode ser aprimorado ao utilizar configurações específicas relacionadas ao usuário, como, por exemplo, bandas de frequência de tempos ideais, que mudam rapidamente e até variam entre tentativas de MI distintas [8]. Nas últimas décadas, diversas metodologias foram propostas com o objetivo de otimizar a seleção de bandas de frequências específicas por usuário, como os métodos baseados em heurísticas [9], métodos de banco de filtros [10] e métodos probabilísticos [11].

Em paralelo, destaca-se também o uso da Geometria Riemanniana, que se mostrou superior aos métodos convencionais, ao deixar de lado o uso de técnicas de filtragem espacial e/ou seleção de características para mapear as informações discriminantes diretamente no espaço geométrico [12]. A distinção de sistemas BCI baseados em tal geometria se dá através da descrição dos sinais de EEG por meio de matrizes de covariância espaciais simétricas positivas definidas - SPD.

Nesse contexto, o estudo proposto apresenta uma nova metodologia para a classificação de MI em sistemas BCI, que utiliza técnicas de seleção e filtragem de bandas de frequência eficientes na variedade Riemanniana. Os sinais brutos de EEG são segmentados em épocas e posteriormente, são geradas sub-bandas de frequências para realizar um janelamento do espectro do sinal. Os recursos discriminativos de cada sub-banda do espaço Riemanniano são extraídos e aprimorados através da Otimização Bayesiana para melhorar a performance do sistema BCI. Além disso, é implementada a fusão de classificação das janelas espectrais através do algoritmo *Light Gradient Boosting Machine* - LGBM. O LGBM, baseado no método *Ensemble*, cria diversos modelos de classificação distintos. Esses modelos, ao serem combinados, proporcionam uma melhoria significativa na precisão final do sistema, que assegura um alto desempenho na classificação da MI.

2 Metodologia

Os sistemas BCI, em geral, são formados por uma cadeia de processos, onde cada um é composto por métodos robustos fundamentais para o funcionamento do sistema. Os principais são: pré-processamento, extração e seleção de características e classificação.

As etapas da metodologia proposta neste estudo são apresentadas de forma visual no diagrama esquemático na **Figura 1**, onde inicialmente os sinais de EEG passam por etapas de pré-processamento, que contempla a etapa **a)** Segmentação; **b)** Transformada Rápida de Fourier dos sinais brutos e ponderamento das informações de frequência por sub-bandas e **c)** Estimação das Matrizes de Covariância. Por fim, são realizadas as etapas **d)** Classificação dos sinais de EEG representados por Matrizes de Covariância através da Distância de Riemann; **e)** Extração de Características; **f)** Fusão de Classificação com o algoritmo LGBM e classificação final da MI. Posteriormente, é fornecida uma descrição detalhada de cada uma das etapas.

A natureza não estacionária dos sinais de EEG é prejudicial para a eficácia dos sistemas BCI, os quais necessitam de etapas de pré-processamento dos sinais brutos, com o objetivo de melhorar a relação sinal-ruído (SNR - do inglês, *Signal-to-Noise Ratio*). As principais etapas de pré-processamento utilizadas neste estudo são apresentadas nas seções de 2.1 a 2.4.

2.1 Segmentação

Durante a aquisição dos sinais de EEG no contexto de sistemas BCI baseados em MI, em geral, os usuários são submetidos a protocolos experimentais que seguem etapas predefinidas para realizar a obtenção de exemplos rotulados para a calibração supervisionada dos algoritmos de aprendizagem [13]. No decorrer de uma única sessão de coleta durante a fase de treinamento, múltiplas repetições do protocolo experimental,




Figura 1 Diagrama esquemático da metodologia proposta neste estudo para a classificação de Imagética Motora (MI) em sistemas BCI. **Fonte:** Autor(2023).

chamados de ensaios, são realizadas para que o usuário possa executar uma série de repetições de cada imagética motora desejada.

No processo de coleta, são apresentadas instruções para o usuário em cada ensaio que formam o conjunto completo dos sinais de EEG em formatos de matrizes bidimensionais, onde as colunas representam os sensores distribuídos no escalpo, chamados de canais, e as linhas são as amostras obtidas através de cada sensor ao longo do tempo, incluindo as pausas entre os ensaios. Os ensaios são compostos de eventos organizados cronologicamente, que garantem que os rótulos dos eventos, em conjunto com as amostras que marcam o início de cada evento, sejam registrados. Dessa forma, torna-se possível a extração de segmentos de EEG sincronizados com a realização da MI [14].

Dentre os eventos registrados, a dica é o evento responsável por instruir o usuário sobre qual tipo de MI realizar e quando deve ser executada. Dessa forma, torna-se um referencial para a segmentação do sinal de EEG na parcela em que ocorre a MI. Com isso, é possível extrair segmentos menores dos sinais, chamados de épocas, que desprezam os sinais que não estão diretamente relacionados com a execução da MI [15]. A segmentação, ao dividir o sinal em épocas específicas relacionadas aos eventos de

interesse, apresenta-se como uma estratégia eficiente para mitigar os efeitos negativos da não estacionariedade dos sinais de EEG.

A não estacionariedade, ao introduzir variabilidade temporal nos sinais de EEG, pode comprometer a estabilidade e confiabilidade dos sistemas BCI. Isso pode resultar em dificuldades na generalização de modelos para diferentes contextos, o que exige estratégias adaptativas contínuas. Além disso, a variabilidade temporal dos sinais pode impactar negativamente a precisão na classificação de padrões neurais associados à intenção do usuário, que torna a segmentação em épocas uma abordagem valiosa para lidar com esses desafios. Observe a representação visual na **Figura 2**, essa configuração de janela selecionada é tipicamente adotada na extração de épocas de EEG em sistemas BCI baseados em MI, sendo utilizada também neste estudo.




Figura 2 Janela temporal com largura de 2 segundos, iniciada 0,5 segundos após a dica visual. Fonte: [16]

2.2 Fast Fourier Transform - FFT dos sinais brutos de EEG

Como mencionado anteriormente, os sinais gerados em resposta a tarefas cognitivas, como, por exemplo, o movimento ou a preparação para a execução do movimento dos membros, são chamados de ERD/ERS¹.

O ERD se traduz em uma redução da potência dos sinais de EEG em uma faixa de frequências específica nos sensores localizados em uma certa região do couro cabeludo, como resultado da dessincronização de um conjunto de neurônios. Já o ERS consiste no aumento da potência de uma faixa de frequências em uma certa zona e reflete também uma sincronização do ritmo oscilatório de um grupo de neurônios [17]. Ambos os fenômenos estão representados na **Figura 3**.

¹ERD/ERS - *Event Related (De)Synchronization*.




Figura 3 Para o gráfico do sensor C3, referente ao hemisfério esquerdo do cérebro, a curva em laranja com o marcador asterisco (*) demonstra a redução de energia (ERD) no espectro do sinal de EEG na faixa de frequência em torno de 12Hz. A curva em azul com o marcador triângulo (▲), representa o espectro do sinal sem dessincronização (ERS). Já para o gráfico do sensor C4 são feitas as mesmas observações, porém, para o hemisfério direito do cérebro do indivíduo. **Fonte:** Autor(2023).

Vale ressaltar também a ocorrência do fenômeno de lateralização cerebral em sistemas BCI baseados em MI. Por exemplo, a imaginação do movimento da mão direita é evidenciada por gerar uma redução de potência nos sensores do hemisfério esquerdo do cérebro, mais especificamente, por volta da localização do sensor C3. Para verificar a ocorrência da imaginação do movimento da mão esquerda, é necessário analisar os sensores do hemisfério direito, localizados por volta do sensor C4.

Com base nas inferências apresentadas, a identificação dos fenômenos neurológicos de ERD e ERS no espectro do sinal de EEG mostrou-se eficaz em comparação aos sinais no domínio do tempo, o que motivou a aplicação da filtragem espectral a partir da Transformada Rápida de Fourier - FFT (do inglês, *Fast Fourier Transform*). Com a aplicação dessa técnica, obteve-se a representação do sinal ao decompô-lo nas bases senoidais a partir de suas harmônicas, sendo transformado em uma matriz de coeficientes cujos componentes mantêm o conteúdo espectral dos sinais de EEG em uma faixa de frequência específica [18].

2.3 Ponderamento das informações de frequência por sub-bandas

O desafio agora passa a ser definir a banda de frequência ideal para cada usuário. Embora métodos para a seleção de bandas de frequências com comprimento fixo em bancos de filtros já tenham sido propostos para classificadores Riemannianos [19], neste estudo, é proposta uma técnica de ponderamento das informações de frequências contidas no espectro do sinal de EEG por meio de janelamento de sub-bandas, com comprimento, quantidade e sobreposição variáveis. Essa abordagem visa garantir novos graus de liberdade para o sistema BCI baseado em MI e Geometria Riemanniana com a melhora da flexibilidade do sistema para diferentes usuários, conforme demonstrado na **Figura 1 b**).

A técnica proposta consiste em, após a aquisição dos sinais de EEG, descrevê-los por meio de um segmento de sinal matricial $Z \in \mathbb{R}^{p \times q}$, em que p representa o

número de sensores e q descreve o número de amostras coletadas a partir de uma taxa de amostragem f_s [17]. Posteriormente é aplicado o algoritmo da FFT e obtém-se a informação espectral contida em Z na forma da matriz $\Gamma \in \mathbb{C}^{p \times q}$ cujos elementos da p -ésima linha são definidos pela Eq.(1):

$$\Gamma_{pc} = \sum_{q=0}^{Q-1} z_{pq} e^{-j \frac{2\pi}{Q} cq}, \forall c = 0, 1, 2, \dots, Q-1 \quad (1)$$

onde z_{pq} representa a q -ésima amostra do p -ésimo sinal em Z e os termos nos c -ésimos coeficientes complexos correspondentes à decomposição do sinal na base de *Fourier*.

Dado que, para identificar os fenômenos neurológicos de ERD e ERS que enfatizam a MI executada, delimita-se as frequências em uma faixa de interesse ao usar filtros digitais, a matriz Γ também pode ser ponderada de modo a contemplar apenas as frequências em Δ_f e selecionar somente os coeficientes correspondentes aos *bins* de frequência entre F_l e F_u , baixa frequência e alta frequência, respectivamente.

O ponderamento das informações de frequência é então realizado através de uma parametrização no domínio do espectro por meio de matrizes de pesos, que realçam as informações discriminantes contidas nos sinais de EEG. A matriz de pesos deve obedecer à restrição das matrizes SPD e defini-la como uma matriz diagonal positiva é uma forma eficiente para atender essa restrição. No entanto, ainda é necessário estabelecer os elementos da matriz diagonal para realizar um ponderamento eficaz.

A função de pertinência gaussiana é bastante popular no contexto de sistemas *fuzzy*; entretanto, nesta abordagem, ela foi aplicada na construção da matriz de pesos por suas facilidades intrínsecas, sendo necessário apenas dois parâmetros, média e desvio padrão para defini-la. Sendo assim, a estratégia adotada para otimizar os parâmetros da matriz de pesos e reduzir o custo computacional do processo é apresentada abaixo na Eq.(2):

$$w(x, c, \sigma) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (2)$$

onde x é a frequência que desejamos ponderar, c é a média e σ o desvio padrão. A **Figura 4** demonstra o mapeamento da região entre $8Hz$ e $30Hz$, com a estratégia adotada neste estudo.

Em síntese, dado que a melhor região do espectro, onde os fenômenos neurológicos de ERD e ERS para a identificação da MI, varia conforme o usuário, garantir uma maior flexibilidade e, consequentemente, melhores resultados de classificação se traduz no janelamento de funções gaussianas ao longo do espectro do sinal de EEG. Isso é feito a fim de encontrar aquela que melhor realça as informações discriminantes no espectro do sinal. Isto posto, foi desenvolvido um algoritmo capaz de ponderar o espectro do sinal EEG em diferentes sub-bandas com a criação de funções gaussianas distintas $w_1, w_2, \dots, w_{N_S-1}, w_{N_S}$, onde N_S é o número de sub-bandas. Com essa aplicação, é possível variar a faixa de frequência de interesse, o comprimento das sub-bandas e a taxa de sobreposição.




Figura 4 A Gaussiana y foi modificada através da Eq.(2) para $c = 15Hz$ e $\sigma = 1.0$. **Fonte:** Autor(2023).

2.4 Estimação das Matrizes de Covariância

Em sistemas BCI, frequentemente, os algoritmos de classificação não utilizam as matrizes de covariância explicitamente como *feature*; contudo, nas abordagens via classificadores baseados na Geometria Riemanniana, as informações do espaço geométrico das matrizes são utilizadas diretamente como *feature*, conforme demonstrado na **Figura 1 c) d)**. Essa metodologia desafia os paradigmas das abordagens clássicas, por excluir a necessidade de filtragens espaciais e/ou seleção de características [12].

Isso se faz possível porque as matrizes de covariância apresentam propriedades estruturais interessantes. Matrizes de covariância são, por construção, simétricas e positivas semi-definidas e, portanto, formam um hipercone não-Euclidiano [20]. No contexto deste estudo, as matrizes de covariâncias dos sinais de EEG são parametrizadas no domínio da frequência através das matrizes de pesos, utilizadas para ponderar as informações discriminantes no espectro do sinal. Essa etapa é definida por meio da Eq.(3):

$$cov\{\Gamma\} = \Gamma \times w \times \Gamma^T \quad (3)$$

2.5 Classificação por Distância de Riemann

Os algoritmos de classificação baseados em métricas de distância, normalmente, são excelentes alternativas para a resolução de problemas. Em sistemas BCI, o uso de uma métrica baseada na geometria de Riemann, atualmente, figura no estado da arte dos classificadores. Essa abordagem destaca-se na literatura por sua robustez e altas taxas de generalização, contudo, há desafios para aumentar sua performance e prevenir falhas durante o processo de classificação do fenômeno [12]. A métrica de distância de Riemann é definida pelo tamanho da geodésica, ou seja, a curva mínima que conecta dois pontos na Variedade de Riemann, definida por meio da equação Eq.(4):

$$\delta_R(C_1, C_2) = \|\log(C_1^{-1}C_2)\|_F = \left[\sum_{i=1}^q \log^2 \lambda_i\right]^{\frac{1}{2}} \quad (4)$$

onde C_1 e C_2 são dois pontos quaisquer e $\|\cdot\|_F$ significa a norma de *frobenius* e λ_i descreve os autovalores da matriz $C_1^{-1}C_2$ [10]. Observe a representação gráfica da Variedade de Riemann na **Figura 5**.




Figura 5 Demonstração da Variedade de Riemann. **Fonte:** [11]

O algoritmo *Minimum Distance to Riemannian Mean* - MDRM, proposto por [10], usa as matrizes de covariância dos sinais de EEG como *features* para classificação e a Geometria de Riemann, pois essas matrizes estão contidas à variedade Riemanniana de matrizes simétricas positivas definidas. A partir da descrição da métrica, o algoritmo MDRM inicialmente para realizar a classificação dos sinais de EEG, calcula a média geométrica para as matrizes de covariância [10], por meio da equação Eq.(5):

$$G^* = \underset{G}{\operatorname{argmin}} \sum_{i=1}^k \delta_R^2(G, \operatorname{cov}\{\Gamma\}_i) \quad (5)$$

Para cada classe deve-se obter uma matriz média correspondente, por exemplo, considerando o cenário descrito na **Figura 5**, suponha que existam as classes A e B, para realizar a classificação é necessário estimar as matrizes médias G_A e G_B . Para definir se um seguimento do sinal, representado por C_1 , pertence à classe A ou B basta calcular a distância de Riemann por meio da equação Eq.(4), entre as médias e C_1 caso ele esteja mais próximo de G_A então $C_1 \in A$ caso contrário $C_1 \in B$.

Portanto, a Geometria Riemanniana oferece uma excelente alternativa para a extração de informações discriminantes para classificação [21]. Nota-se a importância de destacar que o algoritmo é determinístico e apresenta ausência de parâmetros para ajuste. Logo, a metodologia apresentada neste estudo torna a abordagem via MDRM mais flexível, pois há a introdução de graus de liberdade observados na construção das matrizes de covariância.

2.6 Otimização Bayesiana

A Otimização Bayesiana é descrita como uma estratégia de otimização iterativa e guiada por um modelo probabilístico substituto. A abordagem é chamada de Bayesiana por incorporar a lógica do teorema de *Bayes* para descrever propriedades sobre a função objetivo, como suavidade, e direcionar a próxima iteração no espaço com base em um máximo ou mínimo esperado.

O objetivo final dessa estratégia é otimizar a função desconhecida $g(h)$ representada na Eq.(6), chamada de função objetiva, cuja expressão sobre um dado conjunto H é indefinida e portanto possui derivada desconhecida em relação a esse conjunto de

dados. Em termos de maximização global da função objetivo $g(h)$, têm-se:

$$h^* = \arg_{h \in H} \max g(h) \quad (6)$$

A técnica de ponderamento das informações de frequência por sub-bandas apresentada na seção 2.3, busca encontrar a melhor combinação dos hiperparâmetros de faixa de frequência de interesse, comprimento das sub-bandas e a taxa de sobreposição, adequados para diferentes sujeitos. No contexto da otimização de hiperparâmetros, os modelos Bayesianos despontam em termos de eficiência [22], o que justifica a adoção dessa estratégia para automatizar e personalizar o ajuste dos hiperparâmetros no contexto de sistemas BIC baseados em MI. As especificações e configurações relacionadas a utilização da Otimização Bayesiana no contexto deste estudo são apresentadas posteriormente na seção 3 que descreve o experimento realizado.

2.7 Extração de Características

A extração de características de sinais de EEG para fins de classificação, de modo geral, busca fornecer uma representação compacta dos sinais e também com as propriedades que evidenciam as diferenças entre as classes de interesse [12]. Como já citado anteriormente, neste estudo as matrizes de covariâncias ponderadas dos sinais de EEG são utilizadas explicitamente como features em função da quantidade de sub-bandas, ou seja, $\{cov\{\Gamma\}_1, cov\{\Gamma\}_2, \dots, cov\{\Gamma\}_{N_S-1}, cov\{\Gamma\}_{N_S}\}$ sendo utilizadas como entrada para o algoritmo classificador MDRM, resultado em diversas classificações, representadas por $\{MDM_1, MDM_2, \dots, MDM_{N_S-1}, MDM_{N_S}\}$.

O algoritmo classificador baseado na Geometria Riemanniana classifica cada época de interesse, chamado de *trial*, através da menor distância em relação a média da classe A ou classe B, sendo a imagética motora da mão esquerda e mão direita respectivamente, resultado em uma matriz de distâncias $D \in \mathbb{R}^{N_C \times N_T}$, onde N_C é o número de classes e N_T a quantidade de ensaios.

Por fim, é criada a matriz final de *features* que é utilizada como entrada para a fusão de classificação. A matriz é formada pela normalização da matriz D , que resulta em apenas um vetor de *features* que preserva a informação da distância e o sinal positivo ou negativo gerado pela classificação de um determinado *trial*. A combinação desses vetores forma a matriz de *features* final $FT \in \mathbb{R}^{N_T \times N_S}$, conforme demonstrado na **Figura 1 e**).

2.8 Fusão de Classificação com o Algoritmo *Light Gradient Boosting Machine* - LGBM

O LGBM é um algoritmo de Aprendizado de Máquina que pertence à família de métodos Ensemble, uma técnica eficaz em problemas de classificação e regressão [23]. Esses métodos visam melhorar o desempenho ao combinar as previsões de vários modelos de aprendizado de base.

A ideia central por trás dos métodos *Ensemble* é que, ao unir vários modelos aprendizes de base, os erros individuais de um modelo podem ser compensados pelos

acertos de outros, o que resulta em um desempenho global superior em comparação com um único modelo [24].

O LGBM utiliza um algoritmo de folhas (*leaf-wise*) internamente, que constrói as árvores de decisão de forma vertical, conforme ilustrado na **Figura 6**. Sua principal vantagem reside na capacidade de treinamento rápido e eficiente, pois simplifica o processo ao discretizar dados de características contínuas em compartimentos, o que ocasiona uma redução no consumo de memória.




Figura 6 Demonstração da estratégia de divisão por folhas utilizada pelo algoritmo LGBM. **Fonte:** Autor(2023).

2.9 Avaliação de Desempenho

Para avaliar a capacidade do sistema em discriminar com sucesso as tarefas de Imagética Motora (MI), é comumente utilizada a métrica de acurácia de classificação [2]. O desempenho da classificação depende de vários fatores, como a quantidade de dados, o número de características selecionadas, a complexidade do algoritmo, a quantidade de classes envolvidas, entre outros [12].

No contexto deste estudo, a acurácia relaciona o número de exemplos classificados corretamente, p_c , com o número total de ensaios realizados durante o experimento, p_T . Calculada em porcentagem (%) pro meio da Eq.(7):

$$Acc(\%) = \frac{p_c}{p_T} \times 100 \quad (7)$$

A acurácia também é utilizada no processo de otimização, entretanto é interpretada em relação à taxa de erro de *Bayes*, conforme descrito na Eq.(8):

$$Erro = 1 - \frac{p_c}{p_T} \quad (8)$$

3 Experimento

Nesta seção é apresentado o conjunto de dados que foi utilizado para realizar o experimento e um detalhamento sobre as configurações do experimento onde são apresentadas as descrições dos hiperparâmetros que foram otimizados por meio da Otimização Bayesiana.

3.1 Conjunto de Dados

O Dataset utilizado foi obtido no repositório público da IV Competição Internacional de Sistemas BCI, onde o conjunto de dados IIa apresentado por [16] é utilizado. O conjunto de dados é composto por sinais de EEG de 9 sujeitos fragmentados em quatro classes: imaginação motora da mão esquerda (classe 1), mão direita (classe 2), pés (classe 3) e língua (classe 4). Neste conjunto de dados há 22 canais de EEG obtidos sob uma taxa de amostragem de $250Hz$. Individualmente, cada classe possui 144 exemplos, contudo, os experimentos realizados foram conduzidos por uma classificação binária apenas entre os dados da classe 1 e 2.

3.2 Configurações do Experimento

Os experimentos foram executados em nuvem por meio da plataforma Google Colab, com as codificações em linguagem de programação Python na versão 3.10.12; as principais dependências utilizadas foram Numpy 1.26.1, Scikit-Learn e pyRiemman.

Os hiperparâmetros que foram otimizados são:

1. **Frequência Baixa F_l** : utilizada como delimitador inicial da região de busca no espectro do sinal de EEG;
2. **Frequência Alta F_u** : utilizada como delimitador final da região de busca no espectro do sinal de EEG;
3. **Espalhamento σ** : é o desvio padrão da função gaussiana utilizada para ponderar os sinais de EEG, esse parâmetro influencia o espalhamento da função em relação a média;
4. **Taxa de Sobreposição $\cap$** : como cada interação de ponderamento utiliza uma nova função gaussiana em uma região distinta do espectro do sinal, esse parâmetro define a quantidade do espectro do sinal que já foi explorada por uma dada função gaussiana na interação anterior, a nova função gaussiana irá sobrepor, o que ocasiona o janelamento do espectro do sinal.

Vale destacar que o parâmetro de média das funções gaussianas varia em função do espalhamento, não sendo considerado um novo hiperparâmetro para o processo de otimização.

A Otimização Bayesiana foi utilizada por meio da biblioteca *skopt.gp_minimize* integrada ao Scikit-Learn, que utiliza um *kernel* baseado em processo gaussiano para aproximação da função objetivo, em outras palavras, assumi que os valores da função seguem uma gaussiana multivariada. Os parâmetros utilizados foram:

1. **Função para Minimizar**: uma função que conten a referência para o *pipeline* de execução, o espaço de busca e retorna o valor objetivo encontrado em cada interação;
2. **Dimensões**: lista de dimensões do espaço de busca, sendo:
 - $F_l\{4, 5, \dots, 15, 16\}$
 - $F_u\{30, 31, \dots, 39, 40\}$
 - $\sigma\{4, 5, \dots, 9, 10\}$
 - $\cap\{40, 41, \dots, 59, 60\}$

3. **Número de Interações:** foi definido 350 interações para cada sujeito;
4. **Número de Avaliações:** foi definida a execução de 5 interações aleatórias para avaliar o comportamento da função objetivo antes de iniciar o processo de otimização.

O *pipeline* de execução do experimento está detalhado na **Figura 7**, que abrange todos os passos realizados pela metodologia proposta, tanto nas etapas de treinamento quanto nas etapas de teste do modelo final de classificação da MI.




Figura 7 Fluxograma de execução das etapas que compõem a metodologia proposta neste estudo. **Fonte:** Autor(2023).

4 Resultados

Os resultados de classificação em termos de acurácia encontrados por meio da metodologia proposta, estão descritos na **Tabela 1**.

Dentre os resultados preliminares, observa-se uma melhoria na acurácia de classificação para os sujeitos *A08E* e *A09E*, o que evidencia os benefícios de desempenho alcançados pela nova metodologia. Entretanto, para os demais usuários que apresentaram resultados inferiores, é necessário considerar que a perda de informações discriminantes, ocasionada pela região de cauda da distribuição gaussiana utilizada para ponderar as matrizes de covariância, pode ter impactado negativamente os resultados. Nesse sentido, sugere-se explorar diferentes tipos de funções de ponderação, como as funções retangulares, com o objetivo de mitigar esses efeitos adversos. Além disso, é relevante investigar a otimização da quantidade de interações e o aprimoramento das características selecionadas. No entanto, é importante ponderar que o aumento indiscriminado da quantidade de interações pode levar a problemas como *overfitting*, além de potencialmente aumentar o consumo de memória e o tempo de execução.

O conjunto de melhores hiperparâmetros encontrados por meio da Otimização Bayesiana e o tempo de execução da metodologia proposta por sujeitos é apresentado na **Tabela 2**.

Tabela 1 Acurácia de Classificação para o Conjunto de Dados Ila da BCI IV (%)

Sujeitos	Referência	Proposta
A01E	93,17	78,47
A02E	63,19	47,22
A03E	94,44	84,72
A04E	75,00	70,83
A05E	63,19	47,93
A06E	71,53	63,19
A07E	72,92	50,69
A08E	96,53	98,61
A09E	91,67	92,36
Média	80,18 ±13,71	70,45 ±19,47

Resultados da acurácia de classificação obtida pelo método proposto para os sinais de EEG dos 9 sujeitos do conjunto de dados Ila da IV Competição de Sistemas BCI, em contraste com os resultados obtidos pelo método de referência proposto em [11]

Tabela 2 Conjunto de Hiperparâmetros por Sujeitos

Sujeitos	A01E	A02E	A03E	A04E	A05E	A06E	A07E	A08E	A09E
Frequência Baixa (Hz)	16	16	15	14	9	15	4	16	16
Frequência Alta (Hz)	30	40	30	30	30	30	31	32	30
Espalhamento	10	8	10	10	6	9	10	10	10
Sobreposição (%)	41	57	43	40	46	41	52	40	40

5 Conclusão e Trabalhos Futuros

Neste estudo, foi apresentada uma nova metodologia aplicada a sistemas BCI baseados em MI, que opera em uma variedade Riemanniana. Essa abordagem tem a capacidade de mapear diferentes regiões do espectro do sinal de EEG por meio do janelamento de sub-bandas. O objetivo é identificar a sub-banda que melhor realça as informações discriminantes específicas de cada usuário, o que proporciona novos graus de liberdade para aprimorar as etapas de extração e classificação de características e, por conseguinte, a performance do sistema BCI.

Além disso, foi empregada a técnica de Otimização Bayesiana para encontrar a melhor combinação de hiperparâmetros, aliada à fusão de classificação das janelas espectrais por meio do algoritmo LGBM, o que contribui para aprimorar a robustez da metodologia proposta. Os resultados preliminares revelaram uma melhoria na acurácia de classificação para os sujeitos *A08E* e *A09E*, o que indica a importância do desenvolvimento de um *pipeline* consistente em um espaço tangente Riemanniano, desde a seleção da banda de frequência até a etapa de classificação.

Como trabalhos futuros, planeja-se aprimorar as características selecionadas, especialmente aquelas relacionadas à sobreposição de sub-bandas, por meio de novos

ajustes e inferências sobre a influência desse hiperparâmetro na classificação final. Também está prevista a melhoria do algoritmo de janelamento de sub-bandas, com a possibilidade da criação de sub-bandas com variações de comprimento diferentes durante uma mesma interação. Adicionalmente, como uma perspectiva relevante, pretende-se realizar experimentos com um novo conjunto de dados, que contem uma quantidade mais expressiva de ensaios e sujeitos. Nesse contexto, será explorada a utilização de diferentes tipos de funções de ponderação, como as funções retangulares, com o intuito de avaliar o impacto dessas variações na qualidade dos resultados obtidos.

Apêndice A Código Fonte Desenvolvido

Os códigos fontes estão abertos e disponíveis em <https://github.com/danilosl/classify-eeg>.

1. <https://github.com/>
2. <http://www.bbc.de/competition/iv/>

Referências

- [1] Nicolas-Alonso, L.F., Gomez-Gil, J.: Brain computer interfaces, a review. *sensors* **12**(2), 1211–1279 (2012)
- [2] Clerc, M., Bougrain, L., Lotte, F.: Brain-computer Interfaces 1: Methods and Perspectives. John Wiley & Sons, ??? (2016)
- [3] Gandhi, V., Prasad, G., Coyle, D., Behera, L., McGinnity, T.M.: Evaluating quantum neural network filtered motor imagery brain-computer interface using multiple classification techniques. *Neurocomputing* **170**, 161–167 (2015)
- [4] Vaz, Y.: Extração de características para a classificação de imagética motora em interfaces cérebro-computador. PhD thesis, Universidade de São Paulo (2016)
- [5] Silverthorn, D.U.: Fisiologia Humana: Uma Abordagem Integrada. Artmed editora, ??? (2017)
- [6] Pfurtscheller, G., Da Silva, F.L.: Event-related eeg/meg synchronization and desynchronization: basic principles. *Clinical neurophysiology* **110**(11), 1842–1857 (1999)
- [7] Makeig, S., Kothe, C., Mullen, T., Bigdely-Shamlo, N., Zhang, Z., Kreutz-Delgado, K.: Evolving signal processing for brain-computer interfaces. *Proceedings of the IEEE* **100**(Special Centennial Issue), 1567–1584 (2012)
- [8] Arvaneh, M., Guan, C., Ang, K.K., Quek, C.: Optimizing spatial filters by minimizing within-class dissimilarities in electroencephalogram-based brain-computer

- interface. *IEEE transactions on neural networks and learning systems* **24**(4), 610–619 (2013)
- [9] Barachant, A., Bonnet, S., Congedo, M., Jutten, C.: Riemannian geometry applied to bci classification. In: *International Conference on Latent Variable Analysis and Signal Separation*, pp. 629–636 (2010). Springer
 - [10] Barachant, A., Bonnet, S., Congedo, M., Jutten, C.: Multiclass brain–computer interface classification by riemannian geometry. *IEEE Transactions on Biomedical Engineering* **59**(4), 920–928 (2011)
 - [11] Congedo, M., Barachant, A., Andreev, A.: A new generation of brain-computer interface based on riemannian geometry. *arXiv preprint arXiv:1310.8115* (2013)
 - [12] Lotte, F., Bougrain, L., Cichocki, A., Clerc, M., Congedo, M., Rakotomamonjy, A., Yger, F.: A review of classification algorithms for eeg-based brain–computer interfaces: a 10 year update. *Journal of neural engineering* **15**(3), 031005 (2018)
 - [13] Pfurtscheller, G., Neuper, C.: Motor imagery and direct brain-computer communication. *Proceedings of the IEEE* **89**(7), 1123–1134 (2001)
 - [14] Duarte, R.M., et al.: Low cost brain computer interface system for ar. drone control (2017)
 - [15] Wei, Z., Wei, Q.: The backtracking search optimization algorithm for frequency band and time segment selection in motor imagery-based brain–computer interfaces. *Journal of Integrative Neuroscience* **15**(03), 347–364 (2016)
 - [16] Brunner, C., Leeb, R., Müller-Putz, G., Schlögl, A., Pfurtscheller, G.: Bci competition 2008–graz data set a. *Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces), Graz University of Technology* **16**, 1–6 (2008)
 - [17] Silva, C.D., et al.: Processamento de sinais de eeg para classificação de tarefas motoras em sistemas de interface cérebro-máquina (2017)
 - [18] Nawab, S., Oppenheim, A., Willsky, A.: *Sinais e Sistemas*. Pearson
 - [19] Barachant, A.: *pyriemann v0. 2.2*. Zenodo. doi **10** (2015)
 - [20] Bhatia, R.: The riemannian mean of positive matrices. In: *Matrix Information Geometry*, pp. 35–51. Springer, ??? (2012)
 - [21] Congedo, M., Barachant, A., Bhatia, R.: Riemannian geometry for eeg-based brain-computer interfaces; a primer and a review. *Brain-Computer Interfaces* **4**(3), 155–174 (2017)
 - [22] Hutter, F., Kotthoff, L., Vanschoren, J.: *Automated Machine Learning: Methods, Systems, Challenges*. Springer, ??? (2019)

- [23] Rokach, L.: Decision forest: Twenty years of research. *Information Fusion* **27**, 111–125 (2016)
- [24] Sagi, O., Rokach, L.: Ensemble learning: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery* **8**(4), 1249 (2018)