

Combinação de Modelos Personalizados de Interfaces Cérebro-Máquina Baseadas em Imagética Motora com Otimização Bayesiana

Guilherme da Costa Dourado

Faculdade de Engenharia Elétrica
Universidade Federal do Pará (UFPA)
Tucuruí, Brasil
dourado.gui19@gmail.com

Cleison Daniel Silva

PPG em Computação Aplicada
Universidade Federal do Pará (UFPA)
Tucuruí, Brasil
cleison@ufpa.br

Vitor da Silva Jorge

PPG em Computação Aplicada
Universidade Federal do Pará (UFPA)
Tucuruí, Pará
vitor.dsilvajorge@gmail.com

Resumo—Este trabalho investiga a combinação de modelos personalizados de Interfaces Cérebro-Máquina baseadas em Imagética Motora (ICM-IM), otimizados via otimização Bayesiana e combinados por *Bagging*. Foram gerados modelos para classificação binária de seis pares de classes a partir do conjunto de dados público 2a da Competição IV de ICM. As predições dos três melhores modelos de cada par foram combinadas por *Soft Voting*. A performance foi avaliada com o índice κ e sua estatística z_{κ} . Embora a combinação tenha elevado os valores médios de κ , os ganhos não foram estatisticamente significativos, exigindo ajustes metodológicos para melhor desempenho.

Palavras-Chave—Interfaces Cérebro-Máquina, Imagética Motora, Otimização Bayesiana, Aprendizado em Conjunto, *Bagging*, *Soft Voting*.

Abstract—This study investigates the combination of personalized Motor Imagery-based Brain-Computer Interfaces (MI-BCI) models, optimized through Bayesian optimization and combined using *Bagging*. Binary classifiers were built for six class pairs from the public dataset 2a of the BCI Competition IV. The predictions of the top three models for each pair were combined using *Soft Voting*. Performance was evaluated using the κ index and its z_{κ} statistic. Although the ensemble increased average κ values across subjects and class pairs, the improvements were not statistically significant, indicating that methodological adjustments are needed to achieve better performance in binary MI-BCI classification tasks.

Keywords—Brain-Computer Interfaces, Motor Imagery, Bayesian Optimization, Ensemble Learning, *Bagging*, *Soft Voting*.

I. INTRODUÇÃO

Interfaces Cérebro-Máquina (ICMs) baseadas em Imagética Motora (IM) traduzem sinais cerebrais, como os captados por eletroencefalografia (EEG), em comandos para dispositivos externos, sendo úteis em aplicações como mobilidade assistida [1], [2], reabilitação e treinamento em contextos clínicos e educacionais [3]. A imaginação de movimentos, como os de mãos ou pés, gera padrões específicos nos sinais de EEG, que podem ser utilizados para treinar modelos de classificação. Contudo, a baixa amplitude dos sinais, sua suscetibilidade a ruídos e a alta variabilidade interindividual tornam a tarefa de classificação desafiadora [1].

O processamento de uma ICM-IM envolve várias etapas fundamentais, como a extração de épocas, pré-processamento, extração de características e classificação. ICMs personalizadas podem empregar técnicas como os Padrões Espaciais Comuns (*Common Spatial Pattern*, CSP) e Análise Discriminante Linear (*Linear Discriminant Analysis*, LDA) para extração e seleção de características [4]. Quando ajustadas individualmente por métodos como a otimização Bayesiana (*Bayesian optimization*, BO), esses modelos demonstram desempenho satisfatório ao se adaptar às particularidades de cada usuário [4], [5]. No entanto, sua generalização ainda é limitada, o que motiva a investigação de abordagens que combinem os pontos fortes desses modelos personalizados.

O aprendizado em conjunto (*ensemble learning*) surge como alternativa promissora ao explorar múltiplos classificadores para aumentar a robustez e reduzir a variância dos modelos. Métodos de combinação de modelos ICMs como *bagging*, *boosting* e *stacking* e estratégias de decisão final de classificação como votação majoritária e *soft voting* têm sido amplamente estudadas nesse contexto [6]–[9]. Em especial, o *bagging* permite combinar modelos ajustados a partir de subconjuntos amostrados aleatoriamente, promovendo diversidade entre classificadores e mitigando o *overfitting* [6], [7].

Este trabalho tem como objetivo investigar se a combinação de ICMs personalizadas, por meio da técnica de *bagging*, pode melhorar significativamente o desempenho da classificação de IM em uma abordagem binária. São avaliados seis pares de classes motoras extraídas de um conjunto de dados público, com os modelos individuais ajustados por BO. A decisão final é obtida por meio de *soft voting*, que considera as probabilidades preditas por cada classificador. O desempenho é analisado por meio do índice κ e do índice estatístico z_{κ} , oferecendo uma avaliação mais robusta do que métricas tradicionais como acurácia [10].

Este artigo está organizado da seguinte forma: a Seção I apresenta a introdução e o contexto do trabalho; a Seção II discute os fundamentos e as etapas que compõem a cadeia de processamento de uma ICM-IM, além das estratégias de combinação de modelos; a Seção III detalha a metodologia

utilizada em cada etapa; a Seção IV apresenta os resultados obtidos; e a Seção V traz as conclusões do estudo.

II. FUNDAMENTAÇÃO TEÓRICA

Na Seção II, são apresentados os principais conceitos e etapas que compõem uma ICM-IM. Serão abordados os procedimentos de extração de épocas, pré-processamento dos sinais de EEG, extração e seleção de características, classificação dos padrões neurais, bem como estratégias complementares como otimização Bayesiana, aprendizado em conjunto e métricas utilizadas para avaliação do desempenho do sistema.

A. Extração de épocas

Após a aquisição dos sinais, a primeira etapa de processamento de uma ICM-IM consiste na extração de épocas, conforme ilustrado na Fig. 1. A extração de épocas consiste em segmentar o sinal de EEG em janelas temporais fixas que capturam a atividade cerebral relacionada à imaginação motora. Esse processo ocorre durante a fase de treinamento da ICM, sendo essencial para calibrar os algoritmos de classificação. Protocolos experimentais, como o *Graz* [11], utilizam estímulos visuais para indicar ao usuário qual movimento imaginar, permitindo rotular os sinais com precisão. As épocas são geralmente extraídas entre 0,5 e 2,5 segundos após o estímulo, período em que os sinais relacionados à intenção motora estão mais evidentes.




Fig. 1. Cadeia de processamento de uma ICM tradicional.

B. Pré-Processamento

Devido à sua baixa amplitude, os sinais de EEG são altamente suscetíveis a ruídos, como mencionado anteriormente, o que exige a aplicação de técnicas de pré-processamento para melhorar a qualidade dos dados e a eficiência das ICMs. Essa etapa envolve a aplicação de filtros temporais e espaciais com o objetivo de realçar informações relevantes e suprimir interferências.

Uma abordagem comum na literatura atual, é a utilização de um banco de filtros em sub-bandas (*Sub-band Common Spatial Pattern*, SBCSP) para realizar a filtragem temporal e espacial dos sinais. Essa configuração é adotada com base em estudos que indicam as sub-bandas como a estratégia mais eficaz para observar fenômenos característicos da imagética motora, que podem se manifestar de maneira distinta no espectro de frequência de cada indivíduo [12].

O banco de filtros tem como finalidade segmentar o sinal em diversas sub-bandas, que em conjunto cobrem as faixas de frequência dos ritmos μ (8 – 12 Hz) e β (12 – 30 Hz). Em seguida, é aplicado um filtro espacial em cada sub-banda e procede-se à seleção das componentes que melhor representam as intenções motoras. A decisão final do sistema é baseada na fusão dos escores derivados de cada sub-banda analisada.

A filtragem temporal é aplicada para restringir a análise do sinal a frequências relevantes à imagética motora. Normalmente, são utilizados filtros passa-faixa que isolam os ritmos μ e β [13]. Para representar os dados no domínio da frequência, emprega-se a Transformada Rápida de Fourier (*Fast Fourier Transform*, FFT), convertendo o sinal bruto em componentes espectrais que refletem sua composição harmônica.

Já a filtragem espacial tem como função acentuar as informações discriminativas entre os canais, reduzindo a redundância espacial e maximizando a separação entre classes motoras. O algoritmo Padrões Espaciais Comuns é uma das técnicas mais utilizadas nessa etapa [1]. O CSP busca encontrar um conjunto de filtros espaciais que maximize a variância de uma classe motora (ex.: mão esquerda) enquanto minimiza a da outra (ex.: mão direita), como descrito em [14]. Formalmente, para duas classes com matrizes de covariância média C_1 e C_2 , um filtro espacial é obtido extremado a seguinte razão em (1):

$$\arg\max_{\mathbf{w}} = \frac{\mathbf{w}^T C_1 \mathbf{w}}{\mathbf{w}^T (C_1 + C_2) \mathbf{w}}. \quad (1)$$

A solução dessa equação leva à formulação de um problema de autovalores generalizado, visto em (2):

$$C_1 \mathbf{w} = \lambda (C_1 + C_2) \mathbf{w}, \quad (2)$$

onde λ e $\mathbf{w}$ são os autovalores e autovetores, respectivamente. Como descrito em (3), os vetores $\mathbf{w}$ correspondem aos filtros espaciais, e a aplicação desses filtros aos sinais originais $\mathbf{X}$ gera um novo conjunto de dados filtrados espacialmente $\mathbf{R}$:

$$\mathbf{R} = \mathbf{W}^T \mathbf{X}, \quad (3)$$

em que $\mathbf{W}$ é a matriz de transformação cujas colunas são filtros espaciais. Somente os filtros associados aos maiores e menores autovalores são selecionados, pois são os que maximizam a separabilidade entre as intenções motoras. Esses componentes formam um vetor de características de dimensão reduzida, pronto para a etapa subsequente de extração e seleção de características.

C. Extração e Seleção de Características

Após o pré-processamento, a extração de características visa transformar os sinais de EEG em representações mais eficientes das informações relevantes para o experimento [15]. Essa etapa é fundamental para traduzir a atividade cerebral do usuário em comandos úteis para a ICM.

Na abordagem por sub-bandas, as características são extraídas separadamente de cada faixa de frequência, e cada sub-banda é pontuada conforme sua relevância. Para isso,

aplica-se a LDA como meta-classificador, que projeta os dados maximizando a razão entre variância entre classes e dentro das classes.

Devido à presença de ruídos e à variabilidade interindividual dos sinais EEG, apenas algumas sub-bandas contribuem significativamente para a classificação. Assim, uma etapa de seleção de bandas é aplicada para manter apenas as mais informativas. Por fim, os vetores extraídos são fundidos em uma única representação, que pode ser avaliada por métodos como classificadores Bayesianos, utilizando a razão de verossimilhança para gerar uma pontuação final a ser entregue ao classificador decisivo.

D. Classificação

A etapa de classificação visa atribuir as amostras extraídas e processadas às suas respectivas classes motoras. Diversos algoritmos são utilizados, sendo os mais comuns a Análise Discriminante Linear (LDA), Regressão Logística (*Logistic Regression*, LR), Máquina de Vetores de Suporte (*Support Vector Machine*, SVM), Perceptron Multicamadas (*Multi-layer Perceptron*, MLP) e o algoritmo dos K-Vizinhos Mais Próximos (*K-Nearest Neighbors*, KNN).

- A LDA é um algoritmo de classificação que busca separar classes com distribuições Gaussianas e variâncias iguais, além de ser uma técnica de redução de dimensionalidade. Ela utiliza um hiperplano de separação e maximiza a distância entre as médias das classes, minimizando a variância interclasses [16].
- A LR é um algoritmo de aprendizado supervisionado voltado à classificação, especialmente binária, ao prever a probabilidade de um evento com base em variáveis de entrada por meio da função sigmoide [17].
- O SVM, assim como a LDA, utiliza um hiperplano discriminante para separar classes [16], mas seu objetivo é maximizar a margem entre os dados de diferentes classes, aumentando a confiança na classificação.
- O MLP é formado por camadas de unidades inspiradas em neurônios, capazes de aprender operações simples [18]. Suas camadas ocultas e de saída aplicam funções de ativação como sigmoide, tangente hiperbólica (*tanh*), *Rectified Linear Unit* (ReLU) e *softmax*, que introduzem não linearidade e permitem a aprendizagem de padrões complexos [19].
- O classificador KNN determina a classe de uma nova amostra com base na classe da maioria de seus K vizinhos mais próximos, definidos pela menor distância entre uma nova amostra e um conjunto de amostras de treino [20].

E. Otimização Bayesiana

A otimização Bayesiana é uma estratégia para ajuste automático de hiperparâmetros baseada em modelos probabilísticos. A busca por esses valores ótimos não é trivial e pode consumir vastos recursos computacionais e tempo, especialmente quando uma estrutura de ICM é ajustada de forma personalizada para cada sujeito. É nesse contexto que a utilização de algoritmos de otimização se torna essencial [5].

Essa técnica é especialmente útil no ajuste de classificadores em ICMs personalizadas, pois reduz significativamente o tempo de busca por configurações eficazes e melhora a adaptabilidade entre diferentes sujeitos. A estratégia é fundamentada no Teorema de Bayes, que calcula a probabilidade posterior de um modelo $P(M/O)$ a partir de sua verossimilhança $P(O/M)$, da probabilidade a priori $P(M)$ e da probabilidade marginal das observações $P(D)$, conforme mostra (4):

$$P(M/O) = \frac{P(O/M) \cdot P(M)}{P(O)}. \quad (4)$$

F. Aprendizado em Conjunto

O aprendizado em conjunto visa melhorar o desempenho de classificação ao combinar múltiplos modelos, explorando as vantagens individuais de cada classificador. Em ICMs, essa abordagem permite integrar diferentes estruturas ajustadas com hiperparâmetros distintos, o que contribui para maior robustez e menor taxa de erro [18]. As combinações podem ocorrer em várias etapas do processamento e são especialmente eficazes diante da variabilidade dos sinais de EEG. A seguir, são apresentados os algoritmos de aprendizado em conjunto utilizados neste estudo.

1) *Bagging*: O *Bagging* é uma técnica de aprendizado em conjunto que consiste em gerar múltiplos subconjuntos de dados por meio de amostragem com ou sem reposição, sobre os quais diferentes modelos são treinados [6]. As previsões desses modelos são então combinadas, geralmente por votação majoritária ou *Soft Voting*. A Fig. 2 apresenta a estratégia.

Essa abordagem é especialmente eficaz para algoritmos suscetíveis ao *overfitting*, pois promove a diversidade entre os modelos e melhora a capacidade de generalização. No contexto de ICMs, o *Bagging* permite treinar classificadores com diferentes subconjuntos dos sinais de EEG, capturando variações relevantes e gerando uma classificação final mais robusta e precisa.




Fig. 2. Etapas do método de aprendizado em conjunto *Bagging*.

2) *Soft Voting*: O *Soft Voting* é uma técnica de combinação de classificadores em que cada modelo fornece uma probabilidade associada a cada classe. As probabilidades são então agregadas por média, e a classe com maior valor médio é selecionada como a predição final [9]. Também é possível aplicar pesos aos modelos, atribuindo maior influência às previsões dos classificadores mais confiáveis.

G. Métricas de Avaliação

Para avaliar o desempenho dos modelos propostos na classificação da imagética motora, esta pesquisa adota o índice *Kappa*, que avalia a concordância entre as predições de um classificador e os rótulos reais, sendo também útil para verificar se o desempenho observado é estatisticamente superior ao que seria esperado por mero acaso [10]. O índice *Kappa* é definido por (5):

$$\kappa = \frac{P_o - P_e}{1 - P_e}, \quad (5)$$

onde P_o representa a proporção de concordância observada, ou seja, a frequência com que os classificadores produzem a mesma predição. O indicador P_e corresponde à concordância esperada, considerando que as classificações coincidam apenas por acaso. O índice *Kappa* varia de -1 a 1 , onde $\kappa = 1$ indica concordância perfeita, $\kappa = 0$ reflete concordância ao acaso e $\kappa < 0$ sugere desacordo maior do que o esperado por acaso, indicando possível inconsistência nas predições.

Além de quantificar a precisão do modelo, o *Kappa* permite testes estatísticos de significância entre diferentes classificadores. Apresentada em (6), a estatística z_{κ} , obtida a partir da diferença entre dois coeficientes κ_1 e κ_2 e de suas variâncias $\sigma_{\kappa_1}^2$ e $\sigma_{\kappa_2}^2$, segue uma distribuição normal padrão:

$$z_{\kappa} = \frac{|k_1 - k_2|}{\sqrt{\sigma_{\kappa_1}^2 - \sigma_{\kappa_2}^2}}, \quad (6)$$

com isso, é possível calcular o p-valor, que indica se a diferença entre os desempenhos é estatisticamente significativa. Para um nível de significância $\alpha = 0,05$, valores de $z_{\kappa} > 1,96$ indicam significância estatística com 95% de confiança. Caso contrário, não há diferença significativa entre os classificadores.

III. METODOLOGIA

A. Ambiente Experimental e Conjunto de Dados

Os experimentos desta pesquisa foram realizados na plataforma *Google Colaboratory*, que permite o uso de *notebooks Jupyter* em nuvem com recursos computacionais escaláveis. Essa infraestrutura facilita o desenvolvimento, a reprodutibilidade e o compartilhamento das análises. O código foi implementado em *Python*, utilizando as bibliotecas *scikit-learn*, voltada ao aprendizado de máquina [21], e *MNE-Python*, especializada na manipulação e visualização de sinais EEG [22]. Essa configuração viabilizou a execução de todas as etapas do pipeline da ICM-IM, desde o pré-processamento até a classificação.

O conjunto de dados utilizado foi o *dataset 2a* da Competição IV de ICM, uma base pública amplamente reconhecida na área [11]. Ele é disponibilizado em dois subconjuntos, cada um correspondente a uma sessão de coleta. O *dataset* contém sinais de EEG de nove sujeitos em tarefas de imagética motora com quatro classes: mão esquerda (ME), mão direita (MD), pés (PE) e língua (LG), totalizando 288 tentativas por sujeito em cada sessão. Neste estudo, as quatro classes

foram combinadas em pares binários segundo a estratégia um contra um (*one-vs-one*), gerando seis combinações distintas. Os sinais foram registrados por meio de 22 canais com taxa de amostragem de 250 Hz. Cada tentativa, com duração de 4 segundos, foi segmentada em épocas de 2 segundos, produzindo 500 amostras por segmento.

B. Ajuste e Seleção de Modelos ICMs Personalizados

Para cada sujeito da base de dados, os modelos de ICM-IM foram ajustados individualmente com o objetivo de maximizar a acurácia de classificação. Cada etapa da cadeia de processamento definida em II possui múltiplos algoritmos e hiperparâmetros. A Fig. 3 ilustra o processo de ajuste da ICM por etapa, com destaque para os hiperparâmetros considerados. Neste trabalho, esse ajuste foi realizado por meio da plataforma *AutoBCI*, desenvolvida por [4], que automatiza a seleção por meio de otimização Bayesiana. Essa abordagem explora eficientemente o espaço de busca, reduzindo o custo computacional e adaptando-se às variações interindividuais.




Fig. 3. Ajuste de uma interface cérebro-máquina de sub-bandas.

O espaço de busca da otimização Bayesiana é apresentado na Tabela I. A largura da janela ($t_{max} - t_{min}$) foi fixada em 2 segundos, enquanto sua posição temporal variou. A banda de filtragem ($f_h - f_l$) abrangeu frequências associadas à imaginação motora, com sub-bandas configuradas em janelas de 4 Hz e sobreposição de 50%, respeitando os limites da banda total. O número de componentes CSP (n_{csp}) foi limitado ao total de eletrodos disponíveis. Dentre os classificadores testados, cujos hiperparâmetros também foram incluídos no processo de ajuste, a LDA e a LR utilizaram modelos padrões da biblioteca *scikit-learn*.

TABELA I
HIPERPARÂMETROS CONFIGURÁVEIS EM CADA ETAPA DA ICM.

Hiperparâmetro	Variável	Domínio	Etapa da ICM
Janela temporal	t_{min} t_{max}	[0, 0.5, ..., 2.5, 3] [1, 1.5, ..., 3.5, 4]	Extração de épocas
Faixa de frequência	f_l f_h	[0.5, 1, ..., 29, 30] [8, 9, ..., 48, 49]	Pré-processamento
Qtd. de sub-bandas	n_{band}	[1, 2, ..., 23, 24]	Pré-processamento
Qtd. filtros CSPs	n_{csp}	[2, 4, ..., 21, 22]	Pré-processamento
Classificador	clf	[LDA, LR, SVM, KNN, MLP]	Classificação

O ajuste foi realizado para cada um dos seis pares de classes possíveis: {ME, MD}, {ME, PE}, {ME, LG}, {MD, PE}, {MD, LG} e {PE, LG}, conforme a estratégia um contra um. Para cada par, foram extraídas 144 épocas da primeira sessão de cada sujeito. A geração dos modelos de ICM-IM ocorreu por meio de 100 iterações da busca Bayesiana. A cada iteração, avaliou-se o desempenho de classificação médio por meio de validação cruzada 5×5 , com subconjuntos de treino (ET) e de validação (EV) utilizados para estimar a acurácia de generalização em cada configuração.

Ao término das 100 iterações, foram selecionados os três conjuntos de hiperparâmetros com maior acurácia média durante a validação cruzada. Esse processo foi repetido para todos os pares de classes e sujeitos, totalizando 162 ajustes distintos (9 sujeitos $\times$ 6 pares $\times$ 3 modelos ótimos). Os três modelos selecionados para cada par de classes compõem a base para a aplicação das estratégias de aprendizado em conjunto descritas a seguir.

C. Aplicação de Técnicas de Aprendizado em Conjunto

Neste trabalho, a técnica de aprendizado em conjunto adotada é o *Bagging*, aplicada ao contexto da classificação binária de sinais de imagética motora. O objetivo é combinar modelos ICM-IM personalizados, previamente otimizados, a fim de melhorar o desempenho de classificação. Para cada sujeito, são selecionados os três modelos com maior acurácia para cada par de classes, totalizando dezoito modelos. Todos utilizam uma janela temporal padronizada de dois segundos (s), garantindo consistência no número de épocas utilizadas. Porém, com posições temporais distintas entre si (Ex.: $\{[0 - 2], [0, 5 - 2, 5], \dots, [2 - 4]\}$ s), gerando diversidade nos dados de ajuste.

O *Bagging* combina classificadores treinados de forma independente para reduzir a variância do modelo final. Nesta abordagem, os três melhores modelos por par de classes são combinados visando a melhor generalização na distinção entre duas classes específicas. A técnica de decisão utilizada é o *Soft Voting*, em que as saídas probabilísticas dos classificadores são agregadas por média, e a classe com maior valor médio é selecionada como predição final. Essa abordagem favorece a robustez frente a variações individuais nos sinais de EEG.

Para o treinamento dos modelos personalizados, o conjunto total de dados de cada sujeito (incluindo ambas as sessões) foi reamostrado sem reposição para formar quatro subconjuntos de mesma quantidade. Três subconjuntos foram utilizados para o treinamento e o quarto para validação. Cada modelo foi treinado com um subconjunto distinto, promovendo diversidade entre eles. A validação foi realizada com um conjunto comum, composto por amostras extraídas do intervalo de EEG $[0, 5 - 2, 5]$ s. As saídas dos modelos foram então combinadas por *Soft Voting*. A Fig. 4 ilustra a metodologia aplicada.

Esse processo foi repetido quatro vezes, trocando o subconjunto de validação a cada repetição. Assim, cada partição atuou uma vez como conjunto de teste, permitindo uma avaliação mais robusta. A metodologia foi aplicada separadamente para cada um dos seis pares de classes, com modelos combinados




Fig. 4. Esquema de aplicação do algoritmo *Bagging* para a classificação binária.

específicos para cada caso. Espera-se que os classificadores individuais, ao errarem em instâncias distintas, se complementem, potencializando o desempenho do modelo combinado final em comparação aos modelos base.

D. Procedimento de Avaliação dos Modelos

Na abordagem de classificação binária adotada neste trabalho, a avaliação dos modelos é realizada com base em duas métricas principais: o índice κ médio (κ_m) e o índice estatístico z_κ . Essas métricas são aplicadas tanto aos modelos individuais quanto aos modelos combinados obtidos por aprendizado em conjunto, com o objetivo de verificar a confiabilidade estatística dos classificadores e a significância dos ganhos obtidos pela combinação.

O índice κ_m é calculado a partir das matrizes de confusão geradas nas quatro execuções da metodologia para cada par de classes e sujeito. As matrizes são somadas e divididas por quatro, gerando uma matriz média a partir da qual se calcula o coeficiente κ_m . Esse índice avalia a concordância entre as predições e os rótulos reais, desconsiderando os acertos esperados ao acaso, sendo especialmente útil em cenários com múltiplas execuções e variação interindividual.

A significância estatística da diferença entre os desempenhos dos modelos é verificada por meio do índice z_κ , conforme detalhado na Seção II-G. Esse índice é calculado com base na comparação entre o melhor modelo individual e o melhor modelo combinado, considerando o κ_m obtido.

IV. RESULTADOS

Na Seção IV, são apresentados os resultados obtidos tanto para os modelos individuais selecionados, conforme descrito na Seção III-B, quanto para a abordagem de aprendizado em conjunto discutida na Seção III-C.

A Tabela II apresenta os desempenhos dos modelos individuais, bem como os resultados da aplicação do algoritmo *Bagging* para a classificação binária entre os diferentes pares de classes do conjunto de dados utilizado. Os nove sujeitos avaliados, descritos na Seção III-A, estão representados na tabela pela numeração de 1 a 9. Os modelos combinados de cada sujeito, visualizados em [23] e indicados na coluna **Mod**,

TABELA II
RESULTADOS OBTIDOS PARA OS MODELOS INDIVIDUAIS E EM CONJUNTO AVALIADOS.

Suj	Mod	ME x MD			ME x PE			ME x LG			MD x PE			MD x LG			PE x LG		
		κ_m (%)		z_{κ}	κ_m (%)		z_{κ}	κ_m (%)		z_{κ}	κ_m (%)		z_{κ}	κ_m (%)		z_{κ}	κ_m (%)		z_{κ}
		Mod	SV		Mod	SV		Mod	SV		Mod	SV		Mod	SV		Mod	SV	
1	M1	72,92	74,31	0,12	93,75	94,44	0	95,14	95,83	0,14	91,67	96,53	0,15	98,61	99,31	0	43,75	47,22	0,23
	M2	44,44			90,28			93,75			95,83			99,31			36,11		
	M3	60,42			94,44			90,97			93,06			99,31			34,72		
2	M1	5,56	13,19	0	61,11	66,67	0,43	31,94	45,83	0,6	61,11	75,69	0,83	37,5	45,14	0,5	70,83	71,53	0,06
	M2	13,19			60,42			36,81			65,28			33,33			62,5		
	M3	5,56			58,33			35,42			65,97			35,42			56,94		
3	M1	93,06	92,36	0,11	93,06	91,67	0,22	92,36	95,14	0,37	92,36	93,06	0,11	93,75	95,14	0,13	50,69	66,67	0,64
	M2	84,03			80,56			93,06			91,67			89,58			52,08		
	M3	90,28			79,86			87,5			60,42			94,44			58,33		
4	M1	34,72	43,75	0,59	50	75	0,77	65,97	70,14	0,34	63,19	75	0,6	48,61	65,28	0,48	45,14	64,58	1,17
	M2	30,56			65,97			57,64			68,06			59,03			47,22		
	M3	28,17			64,58			63,19			54,17			51,39			48,61		
5	M1	61,81	78,47	1,03	56,25	63,19	0,52	44,44	60,42	0,56	54,17	62,5	0,62	69,44	79,17	0,82	34,03	44,44	0,28
	M2	64,58			47,22			51,39			51,39			70,14			18,06		
	M3	66,67			33,33			52,78			40,28			65,28			40,28		
6	M1	13,89	30,56	0,39	34,72	53,47	1,26	25,69	37,5	0,46	37,5	54,17	0,81	23,61	34,72	0,04	49,31	51,39	0,14
	M2	24,31			43,75			40,28			41,67			34,03			47,92		
	M3	24,31			31,25			22,22			42,36			12,5			18,06		
7	M1	66,67	81,25	0,66	97,92	100	0,71	97,22	98,61	0,41	99,31	100	0,5	97,22	97,22	0	77,78	75	0,26
	M2	60,42			98,61			95,14			98,61			95,83			54,17		
	M3	74,31			97,92			93,75			98,61			95,83			63,89		
8	M1	84,72	90,97	0	77,08	82,64	0,55	90,28	91,67	0,46	77,78	79,17	0,5	77,78	80,56	0,14	74,31	81,94	0,74
	M2	90,97			75			81,25			76,39			77,08			73,61		
	M3	87,5			65,28			85,42			48,61			81,94			64,58		
9	M1	88,19	88,19	0	88,89	88,89	0	93,06	95,14	0,29	68,75	76,39	0,67	85,42	86,81	0,16	77,78	83,33	0,15
	M2	87,5			88,19			95,14			64,58			81,25			76,39		
	M3	83,33			87,5			96,53			68,06			80,56			81,94		
μ		64,58	78,47	-	75	82,64	-	85,42	91,67	-	65,97	76,39	-	77,78	80,56	-	52,08	66,67	-
σ		29,59	29,17	-	21,48	15,88	-	26,26	23,84	-	19,93	15,28	-	26,44	23,13	-	17,54	14,55	-

são identificados como M1, M2 e M3. As siglas ME, MD, PE e LG referem-se, respectivamente, às classes mão esquerda, mão direita, pés e língua.

Ainda na Tabela II, a sigla **SV** representa o algoritmo *Soft Voting*, utilizado como técnica de agregação no *Bagging*. O índice z_{κ} foi calculado a partir da comparação entre o modelo combinado por *Soft Voting* e o modelo individual com maior valor de κ_m . Na parte inferior da tabela, o indicador μ representa a média dos valores de κ_m para os modelos individuais e combinados considerando todos os sujeitos. O símbolo σ representa o desvio padrão correspondente.

A análise dos resultados com base no índice κ_m revela que a combinação de modelos proporcionou melhorias em diferentes pares de classes e sujeitos. Para o par (ME $\times$ MD), os sujeitos 1, 4, 5, 6 e 7 apresentaram desempenho superior com o modelo combinado. No caso de (ME $\times$ PE), os ganhos foram observados nos sujeitos 2, 4, 5, 6, 7 e 8, enquanto para (ME $\times$ LG), os sujeitos 1, 2, 3, 4, 5, 7 e 8 se beneficiaram da combinação. Já para o par (MD $\times$ PE), todos os sujeitos mostraram melhora com o modelo combinado. Nos pares (MD $\times$ LG) e (PE $\times$ LG), os ganhos foram verificados, respectivamente, nos sujeitos 2, 3, 4, 5, 6 e 9, e nos sujeitos 1, 2, 3, 4, 5, 6, 8 e 9.




Fig. 5. Média dos κ_m individuais e combinados considerando os pares de classes e sujeitos avaliados.

A Fig. 5 apresenta a comparação do desempenho médio de κ_m entre pares de classes, considerando modelos individuais e combinados. O par (ME $\times$ LG) obteve os maiores valores em ambas as abordagens, destacando-se como o mais discriminável. Por outro lado, o par (PE $\times$ LG) apresentou os menores desempenhos médios, indicando maior dificuldade

de separação entre essas classes. No geral, todos os pares de classes se beneficiaram da combinação de modelos, com destaque também para os pares (ME $\times$ MD) e (ME $\times$ PE), que apresentaram ganhos expressivos em relação aos modelos individuais. De forma quantitativa, a estratégia de *Bagging* resultou em um aumento médio de aproximadamente 14,4% nos valores de κ_m quando comparada aos modelos individuais.

Esses resultados indicam que, para a maioria dos pares de classes e sujeitos, a estratégia de aprendizado em conjunto proporciona um aumento na confiabilidade estatística da classificação, refletido por maiores valores de κ_m . No entanto, ao avaliar o índice z_κ entre os modelos combinados e os melhores modelos individuais, observa-se que, em nenhum dos casos, a diferença foi estatisticamente significativa. Isso sugere que, embora o aprendizado em conjunto possa melhorar o desempenho médio, os ganhos não são, em geral, estatisticamente robustos frente à variabilidade individual presente nos sinais de EEG.

V. CONCLUSÃO

Este trabalho avaliou a combinação de ICMs personalizadas por meio da técnica de *Bagging* na classificação binária de sinais de imagética motora. A análise quantitativa indicou que a abordagem combinada elevou o índice κ_m em média 14,4% em relação aos modelos individuais otimizados por meio da otimização Bayesiana. Entretanto, os ganhos não foram estatisticamente significativos segundo a estatística z_κ , evidenciando limitações na robustez da metodologia aplicada.

Entre as restrições do estudo, destacam-se o uso de apenas um banco de dados público, a limitação à classificação binária e a ausência de experimentos em protótipos reais. Esses fatores reduzem a generalização dos resultados e indicam a necessidade de cautela quanto à adoção imediata da técnica. Apesar disso, os achados reforçam o potencial do aprendizado em conjunto para lidar com a variabilidade interindividual presente nos sinais de EEG.

Como perspectivas futuras, sugere-se explorar outras estratégias de *ensemble* (como *Boosting* e *Stacking*), ampliar a validação em diferentes bases de dados e implementar a abordagem em protótipos de sistemas práticos. Tais avanços podem ampliar a aplicabilidade do método em cenários reais, como reabilitação motora e sistemas de mobilidade assistida, tornando-o mais consistente e relevante para a comunidade científica e para aplicações clínicas.

REFERÊNCIAS

- [1] F. Lotte, "A tutorial on EEG signal-processing techniques for mental state recognition in brain-computer interfaces," in *Guide to Brain-Computer Music Interfacing*, Londres: Springer, 2014, pp. 133–161. [Online]. Disponível em: <https://hal.inria.fr/hal-01055103>.
- [2] K.-T. Kim, T. Carlson e S.-W. Lee, "Design of a robotic wheelchair with a motor imagery based brain-computer interface," em *Anais do 2013 International Winter Workshop on Brain-Computer Interface (BCI)*, Gangwon, Coreia do Sul, 2013, pp. 46–48, doi: 10.1109/IWWBCI.2013.6506625.
- [3] G. Papanastasiou *et al.*, "Brain computer interface based applications for training and rehabilitation of students with neurodevelopmental disorders: A literature review," *Heliyon*, vol. 6, n. 9, p. e04250, 2020. [Online]. Disponível em: <https://www.sciencedirect.com/science/article/pii/S240584402031094X>.
- [4] V. Vilas-Boas e C. D. Silva, "Configuração automática de hiperparâmetros em sistemas BCI-MI de sub-bandas," em *Anais do XXXVIII Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBRT)*, Florianópolis, SC, Brasil, 2020, p. 5. [Online]. Disponível em: <https://biblioteca.sbrt.org.br/articles/2245>.
- [5] H. Bashashati, R. K. Ward e A. Bashashati, "Bayesian optimization of BCI parameters," em *Anais do 2016 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE)*, 2016, pp. 1–5.
- [6] M. Rahimi *et al.*, "Ensemble methods combination for motor imagery tasks in brain computer interface," em *Anais do 2016 23rd Iranian Conference on Biomedical Engineering e 1st International Iranian Conference on Biomedical Engineering (ICBME)*, 2016, pp. 336–340.
- [7] X. Wei, E. Dong e L. Zhu, "Multi-class MI-EEG classification: Using FBCSP and ensemble learning based on majority voting," em *Anais do 2021 China Automation Congress (CAC)*, 2021, pp. 872–876.
- [8] C. Du, C. Shi, H. Huang e X. Wu, "The motor imagery EEG classification method combining common spatial pattern and ensemble learning," em *Anais do 2021 6th International Conference on Communication, Image and Signal Processing (CCISP)*, Chengdu, China, 2021, pp. 361–366, doi: 10.1109/CCISP52774.2021.9639289.
- [9] K. Sen e B. Verma, "Heart disease prediction using a soft voting ensemble of gradient boosting models, RandomForest, and Gaussian Naive Bayes," em *Anais do 2023 4th International Conference for Emerging Technology (INCET)*, Belgaum, Índia, 2023, pp. 1–7, doi: 10.1109/INCET57972.2023.10170399.
- [10] D. Chicco, M. J. Warrens e G. Jurman, "The Matthews correlation coefficient (MCC) is more informative than Cohen's kappa and Brier score in binary classification assessment," *IEEE Access*, vol. 9, pp. 78368–78381, 2021.
- [11] C. Brunner *et al.*, "BCI competition 2008 – Graz data set A," *Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces)*, Graz University of Technology, vol. 16, 2008. [Online]. Disponível em: <http://www.bbci.de/competition/iv/desc2a.pdf>.
- [12] Q. Novi *et al.*, "Sub-band common spatial pattern (SBCSP) for brain-computer interface," em *Anais do 2007 3rd International IEEE/EMBS Conference on Neural Engineering*, 2007, pp. 204–207.
- [13] T. de J. Lopes, *Estudo, Implementação e Comparação de Diferentes Tipos de Pré-Processamento Aplicados a um Sistema Interface Cérebro-Computador*, Trabalho de Conclusão de Curso (Bacharelado em Engenharia Elétrica), Tucuruí, 2019.
- [14] Z. Tang *et al.*, "Single-trial classification of different movements on one arm based on ERD/ERS and corticomuscular coherence," *IEEE Access*, vol. 7, pp. 128185–128197, 2019.
- [15] J. R. Wolpaw e E. W. Wolpaw, *Brain-Computer Interfaces: Principles and Practice*, Oxford University Press, 2012.
- [16] F. Lotte *et al.*, "A review of classification algorithms for EEG-based brain-computer interfaces: A 10 year update," *Journal of Neural Engineering*, vol. 15, n. 3, p. 031005, abr. 2018. [Online]. Disponível em: <https://dx.doi.org/10.1088/1741-2552/aab2f2>.
- [17] R. Bhuvana, S. Maheshwari e S. Sasikala, "Predict the heart disease using a logistic regression classifier algorithm," em *Anais do 2023 12th International Conference on System Modeling Advancement in Research Trends (SMART)*, 2023, pp. 649–652.
- [18] R. Negri, *Reconhecimento de Padrões: Um Estudo Dirigido*, [S.l.]: [s.n.], 2021. ISBN: 9786555061635.
- [19] J. Z. Esquivel, J. A. C. Vargaw e P. Lopez-Meyer, "Fractional adaptation of activation functions in neural networks," em *Anais do 2020 25th International Conference on Pattern Recognition (ICPR)*, 2021, pp. 7544–7550.
- [20] T. Mladenova e I. Valova, "Comparative analysis between the traditional k-nearest neighbor and modifications with weight-calculation," em *Anais do 2022 International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, 2022, pp. 961–965.
- [21] F. Pedregosa *et al.*, "Scikit-learn: Machine learning in Python," *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.
- [22] A. Gramfort *et al.*, "MEG and EEG data analysis with MNE-Python," *Frontiers in Neuroscience*, vol. 7, n. 267, pp. 1–13, 2013.
- [23] V. da S. Jorge, *Aprendizado em conjunto aplicado à classificação da imagética motora*, Dissertação de Mestrado, Núcleo de Desenvolvimento Amazônico em Engenharia, Universidade Federal do Pará, Tucuruí, 2025. [Online]. Disponível em: <https://repositorio.ufpa.br/jspui/handle/2011/17393>.