

APRENDIZADO EM CONJUNTO APLICADO À CLASSIFICAÇÃO DA IMAGÉTICA MOTORA

João L. S. Azevedo

Faculdade de Engenharia Elétrica
Universidade Federal do Pará (UFPA)
Tucuruí, Brasil
joaolucasazevedo976@gmail.com

Vitor da Silva Jorge

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

Cleison Daniel Silva

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

Abstract—As interfaces cérebro-máquina (ICMs) baseadas em imagética motora (IM) são cadeias de processamento capazes de traduzir a intenção motora do usuário em comando para um dispositivo externo ou virtual. Uma ICM-IM é ajustada com dados rotulados de sinais de Eletroencefalografia (EEG), procedimento capaz de quantificar a atividade elétrica cerebral de um indivíduo. Após o ajuste, a interface deve ser capaz de detectar e distinguir a intenção motora do usuário quando presente no sinal de EEG. As individualidades de cada sujeito e a baixa relação sinal-ruído do EEG são exemplos de desafios para o ajuste das ICMs. Essas interfaces podem ser divididas em dois grandes grupos: classificadores binários e classificadores multiclasse. Os primeiros são especializados em distinguir entre duas classes distintas, enquanto os últimos possuem maior abrangência, sendo capazes de diferenciar múltiplas classes. Diante disso, este trabalho propõe analisar se a combinação de classificadores binários é capaz de produzir um classificador multiclasse mais eficiente. A metodologia é aplicada para um problema de classificação multi-classe utilizando o conjunto de dados público 2a da IV Competição de ICM. Os resultados são apresentados em termos de acurácia de classificação a fim de verificar a relevância da metodologia proposta. Os resultados apontam uma acurácia de classificação média de 74,9%, superando os resultados de dois artigos utilizados para comparação.

Index Terms—Interfaces Cérebro Máquina, Imagética Motora, Eletroencefalografia, Aprendizado em Conjunto, Otimização, Classificação Multi-classe.

I. INTRODUÇÃO

Interfaces Cérebro-Máquina (ICMs) baseadas em Imagética Motora (IM) são cadeias de processamento capazes de traduzir a intenção motora do usuário em comando para ser entregue a um dispositivo externo ou virtual [1].

As ICMs visam analisar padrões presentes em sinais de eletroencefalografia (EEG), os quais são gerados pela atividade bioelétrica cerebral. Todavia, em virtude da natureza sensível e altamente suscetível a ruídos desses sinais, a identificação de padrões confiáveis e consistentes configura-se como uma tarefa complexa, exigindo métodos sofisticados e adaptáveis a cada situação específica.

Para mitigar essa dificuldade, diferentes abordagens estão sendo desenvolvidas ao longo dos anos, abrangendo desde métodos estatísticos clássicos, como regressão logística e análise discriminante, até técnicas mais recentes baseadas em aprendizado de máquina, como redes neurais artificiais,

máquinas de vetores de suporte (SVM, do inglês *Support Vector Machine*) e algoritmos de aprendizado em conjunto. Essas abordagens buscam capturar padrões complexos nos dados e melhorar a capacidade de generalização dos modelos, tornando-os mais eficazes em contextos variados e com diferentes tipos de dados [1].

Um dos métodos utilizados para esse fim é o chamado aprendizado em conjunto, técnica baseada na união dos resultados de múltiplos classificadores especialistas, ponderados de modo a produzir um novo resultado mais preciso e com um maior grau de certeza. Esta técnica tem como objetivo explorar as características de diferentes modelos diante de um problema de classificação, tornando o modelo independente do sujeito o utilizando [2].

Complementarmente, técnicas de otimização vêm sendo incorporadas ao processo de ajuste dos modelos, com destaque para a Otimização Bayesiana (BO, do inglês *Bayesian Optimization*). Essa abordagem permite a seleção automática dos melhores hiperparâmetros para cada conjunto de dados, promovendo uma adaptação mais precisa e eficiente dos algoritmos às características específicas do problema analisado [3].

Em vista do apresentado, o presente trabalho busca então entender se métodos de combinação de classificadores melhoram o desempenho de ICM's ajustadas individualmente para classificação de imagética motora, além de buscar encontrar qual a melhor estratégia de combinação das as ICM's ajustadas.

II. FUNDAMENTAÇÃO TEÓRICA

Na Seção II são apresentadas as definições e contextualizações necessárias para a melhor compreensão das informações apresentadas nesse artigo.

A. ICM com banco de filtros e Classificação

Por se tratar de um sinal de baixa amplitude, o EEG está sujeito a muitos ruídos que podem comprometer a eficiência da ICM [4]. O pré-processamento tem como objetivo isolar o máximo de informação útil possível do sinal bruto e remover os ruídos que o prejudicam, através da aplicação de filtros temporais e filtros espaciais.

Uma estratégia bastante utilizada na literatura atual, na etapa de pré-processamento, é a aplicação de um banco de filtros na configuração de sub-bandas (SBCSP, do inglês *Sub-Band Common Spatial Pattern*) para realizar a filtragem temporal e espacial dos sinais. A escolha por essa configuração baseia-se em estudos que apontam a utilização de sub-bandas como melhor estratégia para observar os fenômenos que definem a imagética motora, que podem ocorrer de forma diferente no espectro do sinal de cada indivíduo [5].

A implementação desse processo consiste na segmentação temporal do sinal em pequenos trechos, chamados de épocas ou janelas de EEG, cada um contendo uma parte do sinal. Cada janela é então processada por um banco de filtros antes de ser encaminhada aos classificadores [6].

O banco de filtros tem como finalidade filtrar o sinal em diferentes sub-bandas, que juntas abrangem a faixa de frequência onde a IM opera. Um filtro espacial é aplicado em cada sub-banda e, posteriormente, é feita uma seleção dos dados que melhor representam cada uma das intenções motoras. A decisão final é derivada da fusão desta pontuação de cada sub-banda, e [7].

A Fig. 1 exemplifica esse processo demonstrando as principais etapas:




Fig. 1. Ajuste de uma interface cérebro-máquina.

A classificação consiste na aplicação de classificadores ou outros algoritmos de aprendizagem de máquina para que os dados recebidos da extração de características sejam interpretados e, então, separados em classes distintas [8]. No caso da ICM baseada em IM, as classes representam as diferentes intenções do usuário que devem ser observadas em sua atividade cerebral monitorada pelo EEG. O desempenho de classificação depende das características extraídas do sinal, o que reforça novamente a importância das etapas anteriores.

Para selecionar o classificador mais apropriado para uma determinada ICM, é essencial entender claramente quais características são usadas, quais são suas propriedades e como são usadas [1]. Para a classificação binária de IM, ou seja, limitada a duas classes, os classificadores lineares como a Análise Linear Discriminante (LDA, do inglês *Linear Discriminant Analysis*) e a Máquina de Vetores de Suporte (SVM, do inglês *Support Vector Machine*) apresentam um bom desempenho. Porém, as características individuais da IM podem dificultar a separação entre as classes de forma linear, o que justifica

a utilização de diferentes tipos de algoritmos de classificação nas ICM's. O Perceptron de Multi-Camadas (MLP, do inglês *Multi-Layer Perceptron*), K-vizinhos mais próximos (KNN, do inglês *K Nearest Neighbors*), Regressão Logística (LR, do inglês *Logistic Regression*) e Árvore de Decisão (DT, do inglês *Decision Tree*) são exemplos de algoritmos comumente aplicados à problemas de classificação [8].

B. Otimização bayesiana

Diferente dos parâmetros do modelo, que são aprendidos automaticamente a partir dos dados durante o treinamento (como os pesos no perceptron de multicamadas), os hiperparâmetros são definidos antes do treinamento e não são ajustados diretamente pela aprendizagem do modelo [9].

A busca por hiperparâmetros ideais em modelos de aprendizado de máquina (*machine learning*, em inglês) é uma das etapas mais cruciais e desafiadoras no desenvolvimento de soluções eficazes, visto que eles influenciam seu comportamento e desempenho durante o processo de treinamento [3].

Uma das estratégias existentes para encontrar-se esse hiperparâmetros é a Otimização Bayesiana (BO, do inglês *Bayesian Optimization*). A BO incorpora o conhecimento prévio sobre a função objetivo e atualiza o conhecimento posterior, aumentando a precisão e reduzindo a perda do modelo [10].

A Fig. 2 exemplifica visualmente o processo através do fluxograma do algoritmo de BO:




Fig. 2. Fluxo da otimização Bayesiana

Após cada avaliação, o modelo probabilístico é atualizado para refletir novas informações, melhorando sua precisão. Várias iterações desse processo são concluídas para ajustar o conjunto de validação e encontrar os hiperparâmetros otimizados que funcionam melhor para o problema de classificação.

C. Aprendizado em conjunto

A aplicação dos algoritmos de classificação depende diretamente das características dos dados e seu contexto e, embora existam muitos tipos de classificadores, a escolha de um só não é suficiente para distinguir as classes dos dados de forma eficiente e robusta. O aprendizado em conjunto é uma vertente que busca ampliar essas possibilidades dos métodos de classificação, ao combinar classificadores conhecidos para resolver os problemas de distinção de classes.

A combinação dos classificadores tem como objetivo explorar as melhores características que diferentes classificadores desempenham diante de uma aplicação. Ao unir esses modelos

ajustados é esperado que se obtenha um desempenho de classificação mais robusto e menores taxas de erro [2].

As técnicas de combinação são diversas e podem ser aplicadas tanto na saída dos classificadores quanto nas etapas de ajuste dos algoritmos. Além disso, os modelos podem dispor ou não de técnicas de otimização, o que aumenta ainda mais as possibilidades dos arranjos. A seguir, são apresentados dois dos algoritmos de aprendizado em conjunto mais comumente utilizados em problemas de classificação.

1) *Soft Voting*: O *soft voting* é uma técnica de aprendizado de máquina que combina as previsões de vários modelos para gerar uma única previsão. No *soft voting*, cada modelo atribui uma probabilidade a cada classe. Essas probabilidades são então combinadas para gerar uma nova probabilidade para cada classe. A classe com a probabilidade mais alta é então escolhida como a previsão final. Outra maneira de implementar o *soft voting* é atribuindo pesos a cada modelo, de modo que as previsões dos modelos mais confiáveis tenham mais peso.

2) *Bagging*: A estratégia de *bagging* começa por amostrar os dados originais com (*bootstrapping*) ou sem reposição, gerando conjuntos de dados variados. Cada conjunto de dados é então usado para treinar um modelo de aprendizado de máquina, como uma árvore de decisão, uma rede neural ou um SVM. Os resultados dos modelos são então agregados para produzir uma previsão final [11]. A predição final é obtida por meio da votação por maioria ou pelo *soft voting*.

No caso da classificação da imagética motora, os classificadores combinados são modelos de ICMs ajustados com diferentes conjuntos de dados. O objetivo é que cada modelo consiga identificar de formas diferentes as intenções motoras do usuário quando presentes nos sinais de EEG, e que a combinação das classificações dos modelos produza uma classificação final mais precisa e robusta.

D. Métricas de avaliação

A fim de avaliar o desempenho dos modelos propostos neste trabalho, no intuito de compará-los com os modelos individuais personalizados, serão utilizadas métricas estatísticas de avaliação de desempenho, a saber, a acurácia de classificação e o índice *kappa*.

As métricas supracitadas podem ser determinadas a partir da matriz de confusão. A matriz de confusão consiste em uma tabela que resume o desempenho do modelo, comparando as previsões feitas pelo modelo com os valores reais (verdadeiros) de uma base de dados. A Fig. 3 exemplifica uma matriz de confusão.

	Classe Esperada				
	ω_1	ω_2	.	ω_c	
ω_1	a_{11}	a_{12}	.	a_{1c}	a_{1+}
ω_2	a_{21}	a_{22}	.	a_{2c}	a_{2+}
.	.	.	.	.	.
ω_c	a_{c1}	a_{c2}	.	a_{cc}	a_{c+}
	a_{+1}	a_{+2}	.	a_{+c}	m

Fig. 3. Exemplo de uma matriz de confusão.

A acurácia de classificação ou acerto global é a métrica mais simples para avaliar o desempenho de modelos de classificação. Ela avalia o percentual de acertos geral da classificação ao dividir o número de acertos pelo número total de classificações, como mostrado em (1),

$$P_o = \frac{1}{m} \sum_{i=1}^c a_{ii}, \quad (1)$$

onde m é o número total de classificações do modelo.

O Índice *kappa* verifica a concordância entre a classificação efetuada e a realidade, assim como pode ser utilizado para determinar se os acertos alcançados são significativamente melhores que uma classificação esperada por acaso [12]. O índice *kappa* é definido em (2),

$$\kappa = \frac{P_o - P_e}{1 - P_e}, \quad (2)$$

onde P_o é a proporção de concordância entre os classificadores, ou seja, a frequência em que os classificadores concordam em suas classificações. O indicador P_e é a proporção de concordância esperada, assumindo que eles estão classificando e concordando por acaso, o qual é apresentado em (3) como

$$P_e = \frac{\sum_{i=1}^c a_{i+} a_{+i}}{m^2}. \quad (3)$$

O valor do índice *kappa* varia de -1 a 1 , onde $\kappa = 1$ significa a concordância perfeita entre a classificação e o esperado. O indicador $\kappa = 0$ reflete concordância igual à que seria esperada por acaso (sem concordância além da chance). E $\kappa < 0$ indica desacordo maior do que o esperado por acaso, o que é raro e indicaria uma discrepância significativa entre o classificador e as predições reais [12].

Outra métrica comum no processo de avaliação de modelos de classificação é a precisão. A precisão mede a quantidade de vezes que o modelo classifica corretamente uma determinada classe em relação ao total de vezes que ele associa um determinado exemplo a essa classe. A precisão de um modelo para uma determinada classe pode ser expressa em (4) como:

$$P_r^i = \frac{a_{ii}}{\sum_{j=1}^c a_{ij}}. \quad (4)$$

A acurácia de classificação é utilizada para avaliar a quantidade de exemplos classificados corretamente pelos modelos avaliados neste trabalho. Os modelos de ICM personalizados devem ser ajustados com diferentes amostras dos sinais de EEG do usuário, de forma que extraiam uma maior variedade de informações da imagética motora. Portanto, espera-se que a combinação dos modelos aumente a quantidade de exemplos classificados corretamente. A análise do índice *kappa* deve confirmar se a combinação dos modelos produz uma diferença estatisticamente significativa, uma vez que os modelos individuais já apresentam um bom desempenho de classificação [12]. Além disso, a precisão deve evidenciar o desempenho dos modelos ao classificar cada uma das classes de imagética motora avaliadas.

III. METODOLOGIA

Este trabalho propõe investigar se a combinação de interfaces cérebro-máquina personalizadas com otimização é capaz de melhorar o desempenho de classificação da imagética motora. A metodologia aplicada também investiga qual é o melhor método de combinar os modelos ajustados ao aplicar e comparar o desempenho de algoritmos de aprendizado em conjunto.

A. Descrição da Bases de Dados

Os dados utilizados nesta pesquisa, os quais seguem um rigoroso protocolo experimental que busca mapear as diferentes regiões do escalpo, a fim de demarcar os períodos de execução da imagética motora.

As coletas são feitas por especialistas e os dados adquiridos são fornecidos por competições de ICM junto com os detalhes do protocolo utilizado. Portanto, o conjunto de dados 2a da Competição IV de ICM [13] é selecionada para o desenvolvimento desta pesquisa.

Este conjunto de dados reúne sinais de EEG coletados de 9 indivíduos diferentes durante a execução de tarefas de imaginação motora, envolvendo quatro classes distintas: mão esquerda, mão direita, pés e língua. O conjunto de treinamento possui 288 tentativas, sendo 72 para cada IM. Os sinais foram coletados de 22 canais de EEG, a uma taxa de amostragem 250 Hz.

B. Ajuste dos Modelos de Interface Cérebro-Máquina

Cada etapa da ICM-IM possui uma gama de algoritmos e técnicas possíveis que podem ser utilizadas para formar a cadeia de processamento dos sinais de EEG e cada algoritmo possui um ou mais hiperparâmetros de ajuste. Neste trabalho, a escolha desses hiperparâmetros é realizada de forma personalizada para os sujeitos dos conjuntos de dados a fim de produzir melhor desempenho de classificação.

Para aumentar a eficiência da busca pelos melhores hiperparâmetros de ajuste para cada sujeito, o experimento conduzido nesta pesquisa utiliza a plataforma AutoBCI desenvolvida no trabalho de [7]. A plataforma utiliza a Otimização Bayesiana para ajustar os parâmetros dos modelos de ICM-IM.

A Otimização Bayesiana é uma técnica de otimização utilizada para encontrar o valor ótimo de uma função com o menor número de avaliações dessa função. No trabalho de [7] a proposta é modelar a acurácia de generalização do classificador final em função dos hiperparâmetros correspondentes e encontrar um conjunto ótimo de valores que minimizam o erro de classificação ou maximizam a acurácia esperada. A modelagem do problema utiliza a abordagem do Estimador de Parzen com Estrutura de Árvore (TPE, do inglês *Tree-structured Parzen Estimator*) e a Esperança de Melhoria (EI, do inglês *Expected Improvement*) como função de aquisição.

O espaço de configuração $\mathcal{H}$, ou seja, o conjunto de hiperparâmetros da ICM-IM a serem otimizados, está representado na Tabela I.

TABLE I
EXEMPLO HIPERPARÂMETROS CONFIGURÁVEIS EM CADA ETAPA DA ICM AJUSTADA

Hiperparâmetro	Variável	Domínio
Largura e localização da janela de EEG	t_{min} t_{max}	$[0, 0.5, \dots, 2.5, 3.0]$ $[1, 1.5, \dots, 3.5, 4.0]$
Banda de filtragem da janela de EEG	t_{min} t_{max}	$[0.5, 1, \dots, 29, 30]$ $[8, 9, \dots, 48, 49]$
Número de sub-bandas	n_{band}	$[1, 2, \dots, 23, 24]$
Número de CSPs	n_{esp}	$[2, 4, \dots, N_{canaís}]$
Classificador	clf	$[LDA, LR, SVM, KNN, MLP]$

Os classificadores, por serem algoritmos distintos entre si, possuem seus próprios hiperparâmetros de ajuste e, portanto, estes estão apresentados na Tabela II. A Regressão Logística (LR) e a Análise de Discriminantes Lineares (LDA) utilizam o modelo padrão da biblioteca scikit-learn [14].

TABLE II
HIPERPARÂMETROS CONFIGURÁVEIS EM CADA CLASSIFICADOR

Classificador	Hiperparâmetros	Domínio
LDA	-	-
LR	-	-
SVM	Regularização Função de Classificação	$[10^8, 10^7, \dots, 10^4]$ [Linear, Polynomial, Gaussian, Sigmoid]
KNN	Número de Vizinhos Próximos	$[2, 3, \dots, NXepocas]$
MLP	Número de camadas ocultas Número de neurônios/Camada Taxa de Aprendizagem	$[1, 2]$ $[10, 20, \dots, 200]$ $[10^5, 10^4, \dots, 10^2]$

C. Aplicação dos Algoritmos de Aprendizado em Conjunto

Para a aplicação do algoritmo de aprendizado em conjunto *Bagging* para a abordagem multi-classe, o conjunto de dados de EEG de um determinado sujeito, contendo as amostras das quatro classes de IM é dividido em quatro conjuntos com diferentes exemplos e de igual quantidade cada. Sendo três utilizadas para treinamento dos modelos personalizados para a distinção binária e um para compor o conjunto de validação multi-classe. A Fig. 4 ilustra a metodologia aplicada.




Fig. 4. Esquema de aplicação do algoritmo *bagging* para a classificação multi-classe.

Na etapa de treinamento, cada modelo é ajustado com um conjunto diferente dos dados de duas classes, para garantir

que os modelos extraíam diferentes informações dos sinais de EEG. Na etapa de validação, os modelos classificam amostras do conjunto de dados multi-classe, sendo essas extraídas da janela de EEG compreendida entre $t_{min} = 0,5$ e $t_{max} = 2,5$ segundos. Após a classificação dos dados de validação, as saídas dos classificadores são combinadas para gerar a classificação final. A estratégia de combinação utilizada é a *Soft Voting*. Este processo é repetido quatro vezes, alternando os conjuntos utilizados para compor o conjunto de validação multi-classe.

D. Avaliação dos modelos propostos

Na abordagem multi-classe, são calculadas, em porcentagem, a acurácia de classificação média, o índice *kappa* médio e a precisão média dos modelos combinados. As métricas descritas são utilizadas para comparar o desempenho das duas metodologias multi-classe. Além disso, é utilizado como comparação o resultado de dois artigos que desenvolvem modelos de ICM para a classificação da imagética motora utilizando a mesma base de dados deste trabalho.

A metodologia descrita busca aproveitar o desempenho individual de cada um dos modelos personalizados para a distinção das quatro classes de imagética motora avaliadas. Naturalmente, a acurácia dos modelos individuais para a distinção das quatro classes é baixa, porém, devem apresentar precisão elevada na distinção de pelo menos duas classes. Ao aplicar o *Bagging* multi-classe, o modelo combinado deve aproveitar essa precisão e apresentar uma acurácia de classificação elevada para as quatro classes.

O primeiro artigo selecionado para comparação é o de [15], onde é desenvolvida uma ICM baseada no algoritmo *Bagging*. O modelo proposto na pesquisa utiliza a filtragem por sub-banda e ajusta diferentes classificadores para então combiná-los utilizando a Votação por Maioria. Os autores da pesquisa apontam que o modelo combinado possui melhor desempenho que todos os modelos individuais combinados. O artigo é utilizado como comparação pois apresenta uma metodologia distinta de aplicação do algoritmo *Bagging*.

O segundo artigo selecionado para comparação de desempenho é o de [16], onde um único modelo é ajustado para a classificação multi-classe utilizando a estratégia "Um versus Um". A pesquisa avalia o método de pré-processamento dos sinais de EEG baseado na geometria de Riemann [17] como alternativa à filtragem espacial utilizando os filtros CSP. Os resultados apontam que a metodologia proposta pelos autores apresentam desempenho, em termos de acurácia, superior aos modelos que utilizam o CSP. O artigo é utilizado como comparação pois apresenta um método alternativo de classificação multi-classe, sem a combinação de modelos ajustados individualmente.

IV. RESULTADOS

Na Seção IV são apresentados os resultados da aplicação da metodologia *Bagging* para classificação multi-classe. A Tabela III apresenta os valores de acurácia e índice *kappa* para cada um dos 9 sujeitos utilizados na pesquisa.

Ao analisar a Tabela III, é possível observar que, para a base de dados avaliada, o *Bagging* apresenta um desempenho satisfatório de classificação em termos de acurácia, com uma média (μ) de 74,86%. O sujeito 7 apresenta a maior acurácia dentre os sujeitos utilizados, com 89,41%. Com relação ao índice *kappa*, o modelo também apresenta um bom desempenho, sendo os sujeitos 2 e 6 os que apresentaram o pior índice.

TABLE III
ACURÁCIA DE CLASSIFICAÇÃO E ÍNDICE *kappa* DO MODELO *Bagging* MULTI-CLASSE.

Sujeito	Métricas de Classificação	
	Acurácia (%)	Kappa (%)
1	80,38	73,84
2	56,42	41,90
3	87,50	83,33
4	69,44	59,26
5	68,08	57,41
6	52,26	36,34
7	89,41	85,88
8	84,20	78,94
9	86,11	81,48
$\mu \pm \sigma$	74,86 $\pm$ 13,88	66,49 $\pm$ 18,51

Ao analisar os resultados da Tabela III, é possível notar que o *Bagging* apresenta, em média, precisão de classificação superior a 70% para todas as classes da base de dados avaliada. Os resultados sugerem que o modelo proposto é capaz de distinguir de maneira eficiente os padrões das quatro classes de imagética motora dos usuários.

TABLE IV
ACURÁCIA DE CLASSIFICAÇÃO E ÍNDICE *kappa* DO MODELO *Bagging* MULTI-CLASSE.

Sujeito	PRECISÃO			
	MD	ME	PE	LG
1	86,11	87,50	71,53	74,31
2	44,44	45,14	81,53	55,56
3	93,06	93,75	75,69	85,42
4	68,06	56,94	70,83	69,44
5	70,14	76,39	59,72	63,89
6	52,78	40,97	54,86	46,53
7	91,67	91,67	87,50	86,81
8	88,19	83,33	79,86	85,42
9	91,67	79,86	78,47	90,28
$\mu \pm \sigma$	76,24 $\pm$ 18,25	72,84 $\pm$ 20,05	73,10 $\pm$ 10,45	73,07 $\pm$ 15,41

A Tabela V apresenta a acurácia de classificação dos dois modelos propostos nesta pesquisa e os resultados de acurácia dos artigos selecionados para comparação. Como esperado, não há uma abordagem que é melhor para todos os sujeitos avaliados devido as características únicas de cada sujeito.

No entanto, o *Bagging* proposto nesta pesquisa supera os resultados das pesquisas de [15] e [16] para seis sujeitos (3, 4, 5, 7, 8 e 9). Ao analisar a média das acurácias (μ) de todos os sujeitos e o desvio médio padrão (σ), é possível notar que o *Bagging* apresenta a maior média de acurácia, com 74,9% e o segundo menor desvio padrão, com 13,9%, superando as demais metodologias avaliadas.

Além disso, os menores valores de acurácia apresentados pelas abordagens propostas nesta pesquisa (52%) superam os menores valores de acurácia apresentados pelos artigos de [15] e [16], sendo 44,4% e 45%, respectivamente.

TABLE V
COMPARAÇÃO DO DESEMPENHO DE ACURÁCIA (%) ENTRE O MODELO PROPOSTO E OS RESULTADOS DOS ARTIGOS SELECIONADOS.

Sujeito	Acurácia (%)		
	Bagging	Artigo 1	Artigo 2
1	80,4	81,9	80,5
2	56,4	58,0	51,3
3	87,5	76,7	87,5
4	69,4	64,2	59,3
5	68,1	61,8	45,0
6	52,3	44,4	55,3
7	89,4	83,0	82,1
8	84,2	76,7	84,8
9	86,1	69,8	86,1
$\mu \pm \sigma$	74,9 $\pm$ 13,9	68,5 $\pm$ 12,7	70,2 $\pm$ 17,1

V. CONCLUSÃO

O desenvolvimento de uma ICM personalizada busca explorar as características particulares que a IM de cada sujeito possui para produzir resultados de classificação mais eficientes. Enquanto o aprendizado em conjunto tem como princípio básico combinar os resultados de modelos treinados de forma independente para reduzir a variância do modelo final e, assim, melhorar seu desempenho. Assim, este trabalho investiga se a combinação de ICMs personalizadas é capaz de melhorar o desempenho de classificação da imagética motora de forma significativa.

A aplicação dos algoritmos de aprendizado em conjunto é realizada por meio de uma abordagem multiclasse. Os resultados são avaliados em termos de acurácia de classificação, índice *Kappa* e precisão. Além disso, os valores de acurácia obtidos são comparados com os resultados de dois artigos que propõem ICMs voltados à classificação multiclasse.

Os resultados sugerem que o critério escolhido para a seleção dos modelos otimizados deve ser reavaliado, levando em consideração o índice z_{κ} entre os modelos selecionados. A estratégia mencionada deve garantir que o modelo final combinado obtenha uma diferença estatística maior com relação aos modelos individuais. Também é pertinente reavaliar a divisão do conjunto de dados utilizado para o ajuste dos modelos, utilizando estratégias de reamostragem com reposição, para aumentar a variabilidade dos conjuntos.

Os resultados obtidos expõem que a combinação dos modelos é capaz de aproveitar a especialidade que cada modelo binário possui na distinção de duas classes para realizar a distinção das quatro classes avaliadas. O *Bagging* apresenta a melhor acurácia de classificação superando, inclusive, os dois artigos selecionados para comparação.

Enfim, futuras pesquisas podem explorar a metodologia exposta neste trabalho para outras base de dados públicas. Também é importante avaliar a aplicação de outros algoritmos

de aprendizado em conjunto, além de estudar a adição de novos modelos ajustados com otimização.

REFERENCES

- [1] VILAS-BOAS, V.; JORGE, V.; SILVA, C. D. Towards ideal time window for classifying motor imagery in brain-computer interfaces. In: Anais do VIII Symposium on Knowledge Discovery, Mining and Learning. Porto Alegre, RS, Brasil: SBC, 2020. p. 73–80. ISSN 2763-8944. Disponível em: <https://sol.sbc.org.br/index.php/kdmile/article/view/11961>.
- [2] BRUNNER, C. et al. BCI competition 2008 – graz data set a. Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces), Graz University of Technology, v. 16, 2008. Disponível em: http://www.bbci.de/competition/iv/desc_2a.pdf. Acesso em: 14 mar. 2020.
- [3] NOVI, Q. et al. Sub-band common spatial pattern (sbccsp) for brain-computer interface. In: 2007 3rd International IEEE/EMBS Conference on Neural Engineering. [S.l.: s.n.], 2007. p. 204–207.
- [4] NEGRI, R. Reconhecimento de Padrões: Um estudo dirigido. [S.l.: s.n.], 2021. ISBN 9786555061635.
- [5] WEI, X.; DONG, E.; ZHU, L. Multi-class mi-ecg classification: Using fbccsp and ensemble learning based on majority voting. In: 2021 China Automation Congress (CAC). [S.l.: s.n.], 2021. p. 872–876.
- [6] MIAO, Y. et al. Learning common time-frequency-spatial patterns for motor imagery classification. IEEE Transactions on Neural Systems and Rehabilitation Engineering, v. 29, p. 699–707, 2021.
- [7] KANG, J.-S.; KAVURI, S.; LEE, M. Adaptive eeg noise filtering for coherence analysis. In: 2014 International Winter Workshop on Brain-Computer Interface (BCI). [S.l.: s.n.], 2014. p. 1–4.
- [8] CHICCO, D.; WARRENS, M. J.; JURMAN, G. The matthews correlation coefficient(mcc) is more informative than cohen's kappa and brier score in binary classification assessment. IEEE Access, v. 9, p. 78368–78381, 2021.
- [9] BARACHANT, A. et al. Multiclass brain-computer interface classification by riemannian geometry. IEEE Transactions on Biomedical Engineering, v. 59, n. 4, p. 920–928, 2012.
- [10] DAULTON, S. et al. Unexpected improvements to expected improvement for bayesian optimization. In: Proceedings of the 37th International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2024. (NIPS '23).
- [11] LOTTE, F. A tutorial on EEG signal-processing techniques for mental state recognition in brain-computer interfaces. In: Guide to Brain-Computer Music Interfacing. Springer, London, 2014. p. 133–161. ISBN 978-1-4471-6583-5. Disponível em: <https://hal.inria.fr/hal-01055103>. Acesso em: 11 out. 2019.
- [12] BASHASHATI, H.; WARD, R. K.; BASHASHATI, A. Bayesian optimization of bci parameters. In: 2016 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE). [S.l.: s.n.], 2016. p. 1–5.
- [13] CONGEDO, M.; BARACHANT, A.; BHATIA, R. Riemannian geometry for eeg-based brain-computer interfaces; a primer and a review. Brain-Computer Interfaces, v. 4, p. 1–20, 03 2017.
- [14] PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. Journal of Machine Learning Research, v. 12, p. 2825–2830, 2011.
- [15] MITRA, P.; BIESSMANN, F. Automated computational energy minimization of ml algorithms using constrained bayesian optimization. 07 2024.
- [16] HALTA, S. K.; ERGÜZEN, A.; ERDAL, E. Classification methods in eeg based motor imagery bci systems. In: 2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT). [S.l.: s.n.], 2019. p. 1–5.
- [17] RAHIMI, M. et al. Ensemble methods combination for motor imagery tasks in brain computer interface. In: 2016 23rd Iranian Conference on Biomedical Engineering and 2016 1st International Iranian Conference on Biomedical Engineering (ICBME). [S.l.: s.n.], 2016. p. 336–340.