

# Interface Cérebro-Máquina baseada em Imagética Motora: Estudo comparativo da quantidade de canais de EEG

Tayla de J. Lopes, William Machado, Jhoanyn V. F. Calvino, Vitor M. Vilas-Boas, Cleison D. Silva

**Abstract**—O trabalho desenvolvido consiste em implementar um sistema interface cérebro-computador (ICM) baseado na imagética motora de duas classes. O registro da atividade elétrica cerebral é realizado através de sinais de Eletroencefalograma - EEG. O objetivo é avaliar a utilização de uma quantidade reduzida de eletrodos posicionados no escalpo do usuário da ICM para o registro do EEG, sem comprometer significativamente a acurácia de classificação dos sinais de EEG. No total, oito sensores são posicionados sobre o couro cabeludo para a coleta dos sinais de EEG realizada via *OpenBCI Cyton board*. Os algoritmos para tratamento dos sinais de EEG são implementados em software específico para ICM e distribuído gratuitamente - *OpenVibe*. Os resultados são apresentados em bloco com base na acurácia obtida para cada cenário.

**Index Terms**—ICM, Interface Cérebro-Máquina, EEG, Banco de filtros, CSP, LDA, Imagética Motora.

**Abstract**—The work developed here consists in the implementation of a motor imagery (MI) based Brain-Computer Interface (BCI). The registering of the brain's electric activity is performed through electroencephalogram (EEG) signals. The aim is to evaluate the use of a small amount of electrodes positioned on the ICM user's scalp to register the EEG without significantly compromise the accuracy of the EEG signals ranking. Altogether, eight sensors are placed on the scalp to collect the EEG signals made through the OPENBCI Cyton board. The algorithms for handling the EEG signals are implemented on a software specific for BCI, that is freely distributed to the public. The results are presented in blocks, based on the accuracy obtained for each scenario.

**Index Terms**—BCI, Brain-Computer Interface, EEG, Filter Bank, CSP, LDA, Motor imagery.

## I. INTRODUÇÃO

Interfaces Cérebro-Máquina (ICM) baseadas em imagética motora (IM) são sistemas que possibilitam aos seus usuários o envio de comandos associados a intenção motora para o controle de dispositivos [1]. A decodificação dos comandos é realizada a partir da detecção de mudanças em propriedades de ondas elétricas registradas da atividade cerebral a partir da imaginação de um movimento[2].

O registro das ondas cerebrais em sistemas de ICM-IM é usualmente realizado por eletroencefalografia (EEG), uma técnica não-invasiva que utiliza sensores posicionados no escalpo[1][11]. Fatores como boa resolução temporal, equipamentos portáteis e custos inferiores em comparação com outros métodos de registro da atividade cerebral justificam sua popularidade [4].

Ao realizar a IM, o usuário é capaz de alterar as características dos sinais de EEG tanto espacialmente quanto

em frequência [5]. Assim, a atividade elétrica cerebral pode ser coletada utilizando um amplificador e os sinais de EEG disponibilizados para processamento e análise [3].

Em sistemas ICM-IM, algoritmos de tratamento de sinais são desenvolvidos a fim de filtra-los em faixas de frequências específicas associadas aos ritmos sensório-motores e realizar transformações com o objetivo de explorar as características do sinal bem como as informações contidas na distribuição espacial dos eletrodos no escalpo [6].

Muito esforço tem sido empreendido pela comunidade científica da área com o intuito de desenvolver algoritmos que consigam decodificar a intenção motora do usuário de forma confiável e robusta [6]. Uma cadeia de processamento comumente adotada em projetos de ICM-IM consiste em filtrar os sinais de EEG em uma única faixa de frequência, combinar linearmente os sinais resultantes através de filtragem espacial, extrair e selecionar as características associadas a IM e classifica-las com base na intenção motora do usuário [7].

Na etapa de filtragem temporal, filtros de resposta impulsiva infinita (IIR) são amplamente utilizados[8]. Para a tarefa de combinar linearmente os sinais filtrados, os filtros espaciais do tipo Padrões Espaciais Comuns (CSP) são bastante utilizados[9]. Após a filtragem via CSP, a energia média dos sinais resultantes, é utilizada para compor as características dos sinais [10], que são submetidas à um classificador, por exemplo, Análise de Discriminantes Lineares (LDA) [11].

Estudos sugerem que a utilização de um número elevado de sensores em ICMs baseadas em IM tendem a melhorar o desempenho desses sistemas, haja vista que mais informações acerca do estado mental do indivíduo podem ser extraídas [19]. Nesse caso, ao aumentar a quantidade de sensores distribuídos no escalpo, os filtros espaciais, do tipo CSP, são uma boa alternativa para o processamento dos sinais de EEG uma vez que exigem uma abordagem multicanal [20].

No entanto, além de representar aumento na dimensionalidade dos dados e conseqüentemente aumento do custo de processamento, a ampliação da quantidade de sensores impõe restrições práticas ao sistema. Ferramentas de aquisição mais caras, maior demanda de tempo para preparo da coleta dos sinais de EEG ou mesmo, desconforto ao usuário pela quantidade excessiva de sensores, fios e gel condutor são algumas dessas restrições [12].

Nesse contexto, abordagens que utilizem uma quantidade reduzida de canais a partir da seleção dos pontos mais relevantes têm chamado a atenção da comunidade científica

[13][19]. Agilizar o processo de aquisição e da configuração do sistema, reduzir a dimensionalidade dos dados e possibilitar a identificação da região do cérebro mais representativa em relação à tarefa motora são algumas das motivações para fazê-lo [21].

Estratégias híbridas [26], baseadas em técnicas de filtragem [24][27] e de empacotamento [25][28] têm sido propostas com intuito de selecionar e avaliar subconjuntos de canais de EEG [21]. Além disso, abordagens baseadas em algoritmos de extração de características, como o CSP, também são frequentemente propostas a fim de viabilizar projetos de ICM baseados em IM que utilizam um número reduzido de canais [20][13][22][23].

Neste trabalho, cenários que implementam um sistema de ICM-IM de duas classes, projetados a partir de quantidades reduzidas de canais, são propostos. O objetivo é avaliar a aplicação de estratégias baseadas em banco de filtros (BF) combinadas ao algoritmo CSP como alternativa ao uso excessivo de sensores, sem comprometer significativamente o desempenho do sistema na discriminação entre as classes de IM.

O artigo está organizado em seções. Na segunda seção, os materiais e métodos utilizados no trabalho são descritos. A seção 3 apresenta as etapas de processamento de sinais de EEG aplicadas no contexto de sistemas ICM baseados em IM. Por fim, os resultados e conclusões são apresentados e discutidos nas seções 4 e 5, respectivamente.

## II. MATERIAIS E MÉTODOS

### A. Aquisição dos sinais de EEG

O procedimento de registro da atividade elétrica cerebral é realizado utilizando-se equipamentos para aquisição de sinais de Eletroencefalografia (EEG). Os sinais de EEG são amplamente utilizados em ICM-IM por apresentarem características favoráveis à ambientes fora de laboratórios, como: boa resolução ao temporal dos sinais, portabilidade custo relativamente inferior dos equipamentos, além de necessitar de um procedimento não invasivo para o registro dos sinais.

Um sistema de aquisição de sinais de EEG da empresa *OpenBCI* é utilizado. As principais características técnicas do sistema de aquisição consistem em: registrar até 8 sinais de EEG simultaneamente e amostrados à 250 ciclos por segundo [2].

O registro dos 8 sinais de EEG é realizado posicionando-se eletrodos [] em localizações específicas no escalpo do usuário da ICM-IM. A distribuição dos eletrodos no escalpo adotado segue o padrão internacional para posicionamento de eletrodos via EEG [2]. As localizações dos eletrodos consistem em: *Cz*, *Cpz*, *C3*, *C1*, *Cp3*, *C2*, *C4* e *Cp4*. Na Figura 1 observa-se a distribuição dos eletrodos adotada (à esquerda), assim como uma imagem dos eletrodos (à direita) fixados no escalpo do usuário. A fixação dos eletrodos no escalpo é realizada com o auxílio de gel com propriedades que facilitam a condução elétrica apropriados o registro de sinais de EEG [2].

A escolha desses canais está relacionada com o tipo de atividade mental a ser desenvolvida. Pois, a IM possui

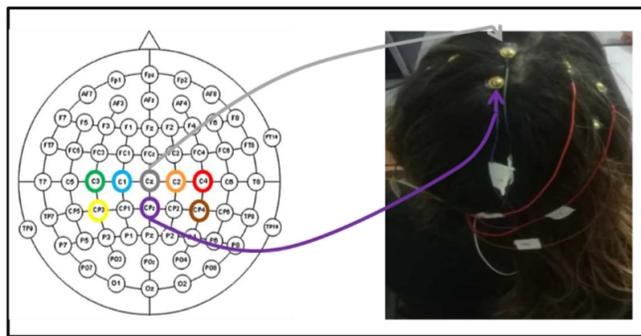


Figure 1. À esquerda, diagrama esquemático com as posições padronizadas dos eletrodos durante coleta de sinais de EEG. À direita, exemplo de localização dos eletrodos no escalpo.

um padrão definido gerado através de sua sincronização e dessincronização que ocorre na região central do cérebro, região esta que está relacionada com a área sensora e motora [33].

### B. Protocolo experimental

O registro da atividade cerebral via sinais de EEG é realizado seguindo um protocolo experimental pré-definido. A finalidade é o de utilizar os sinais de EEG após a coleta para ajustar a cadeia de algoritmos de tratamento de sinais que formam a ICM-IM. No protocolo experimental é definido os procedimentos utilizados durante a coleta dos sinais de EEG.

O registro dos sinais de EEG é realizado com o usuário da ICM-IM sentado confortavelmente em uma cadeira com braços de descanso [2]. O usuário é posicionado de frente para um monitor de computador onde instruções de orientação da coleta são apresentadas [31].

A sequência de instruções é apresentada ao usuário seguindo a base de tempo definido na Figura 2. A sequência completa de instruções tem duração de 8 segundos e é subdividida em 4 eventos. Primeiramente, um sinal sonoro na forma de *beep* é disparado e indica que a sequência de instruções teve início; concomitante ao sinal sonoro é apresentada no monitor uma imagem em forma de cruz, que fica visível por 2 segundos de duração. Em seguida, destina-se um intervalo de 1 segundo de duração em que o usuário deve aguardar o aparecimento de uma imagem no monitor. A imagem corresponde a uma "dica". A dica é exibida durante 1 segundo e é apresentada por meio de imagens de setas, direcionadas para à direita ou para à esquerda, correspondendo a imagética motora que deve ser realizada pelo usuário nos 4 segundos subsequentes [31].

Uma sequência completa de eventos, mostrados na Figura 2, é comumente nomeada de "tentativa". Duas sessões de coleta de sinais de EEG foram realizadas. Cada uma das sessões contém 40 tentativas, 20 tentativas de imagética motora da mão direita e 20 da mão esquerda, respectivamente.

A sequencia escolhida é bastante difundida nas competições de BCI, as quais produzem data sets baseados em tempos semelhantes ao escolhido nessa sequencia. Um exemplo disso é o conjunto de dados disponibilizado no website do evento

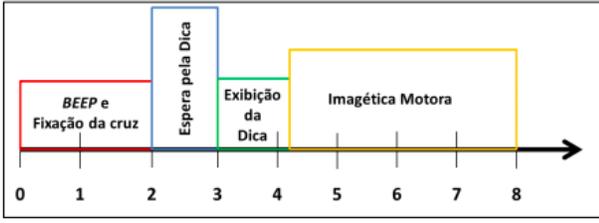


Figure 2. Sequencia de instruções para o desenvolvimento do protocolo experimental, o qual tem duração de 8 segundos e é subdividido em 4 partes.

“BCI Competition IV” [32], que possui uma sequencia muito semelhante e tem sido utilizado por vários pesquisadores da área desde a sua publicação em 2008.

### III. PROCESSAMENTO DE SINAIS DE EEG

Nesta seção as principais etapas da cadeia de processamento de sinais de EEG aplicados a ICM baseadas de IM são descritas. A sequência de processamento consiste das seguintes etapas: filtragem temporal, filtragem espacial, extração e seleção de características e classificação de sinais de EEG associados a imagética motora das mãos direita e esquerda.

#### A. Formulação do problema

Os sinais de EEG associados a IM registrados em conformidade com o protocolo experimental apresentado em II-B, são subdivididos em trechos contendo as amostras dos sinais e um rótulo, indicando a qual IM o sinal é correspondente.

Os trechos dos sinais de EEG são organizados no conjunto  $\mathcal{C} = \{\mathbf{Z}^{(i)}, t^{(i)}\}$ , em que os elementos de  $i = 1, \dots, N_1$  correspondem a classe  $\mathcal{C}_1$  e, os elementos de  $i = N_1 + 1, \dots, N_1 + N_2$  correspondem aos elementos da classe  $\mathcal{C}_2$ . Cada uma das classes,  $\mathcal{C}_1$  e  $\mathcal{C}_2$  apresentam, respectivamente,  $N_1$  e  $N_2$  elementos. Cada trecho do sinal de EEG é um elemento do conjunto  $\mathcal{C}$  e é representado por  $\mathbf{Z} \in \mathbb{R}^{p \times q}$ , em que contem os sinais correspondentes ao eletrodo na posição  $p$  e  $q$  amostras por eletrodo. A variável  $t \in \{1, 2\}$  indica a classe correspondente do trecho de sinal de EEG, sendo  $t = 1$  para  $\mathcal{C}_1$  e  $t = 2$  para  $\mathcal{C}_2$ .

#### B. Filtragem Temporal

A primeira etapa para o processamento de sinais de EEG, no contexto de sistemas ICM, consiste em filtrar os sinais com os objetivos de selecionar a faixa de frequência do sinal associada à imagética motora e também, atenuar a interferência de ruídos nos sinais.

A etapa de filtragem pode ser realizada por um único filtro passa-faixa definido na faixa de frequência em que ocorre a IM. Ou ainda, utilizando-se um banco de filtros, o que permite visualizar em sub-bandas os efeitos da IM no EEG [18] e [14].

1) *Faixa de frequência  $\Delta f$* : A faixa de frequência  $\Delta f$  corresponde ao intervalo de frequências compreendido entre 6 e 32 Hz. A faixa  $\Delta f$  contem os ritmos  $\mu$  e  $\beta$  da atividade cerebral, conforme descrito em [].

Sendo assim, seja  $\mathbf{X} \in \mathbb{R}^{p \times q}$  a versão filtrada de  $\mathbf{Z}$  na faixa de frequência  $\Delta f$ .

2) *Sub-faixa de frequências  $\delta f$* : A faixa de frequências  $\Delta f$  pode ser subdividida em  $K$  faixas de frequências  $\delta f$  com sobreposição de 50% entre si. Representa-se esse subdivisão como segue, seja  $\mathbf{X}_k$ , a versão do sinal  $\mathbf{Z}$  filtrado na  $k$ -ésima sub-faixa  $\delta f$ , com  $k = 1, 2, \dots, K$  [].

#### C. Filtragem Espacial

Para a realização da filtragem espacial é utilizado o algoritmo padrões espaciais comuns - CSP, []. O CSP é amplamente utilizado no pré-processamento de sinais de EEG em ICM baseados em IM das mãos direita (MD) e esquerda (ME) e favorece desempenho de classificação satisfatórios dos sinais [15].

Nessa etapa, os sinais espacialmente filtrados correspondem à versões linearmente combinadas dos sinais filtrados no tempo. A combinação linear é realizada através de uma transformação espacial definida pela matriz quadrada  $\mathbf{W} \in \mathbb{R}^{p \times p}$ . Cada coluna de  $\mathbf{W}$  representa um filtro espacial.

A filtragem espacial é dada por,

$$\mathbf{Y}^{(i)} = \mathbf{W}^T \mathbf{X}^{(i)}, \quad (1)$$

para  $i = 1, \dots, N_1 + N_2$ .

A determinação da matriz  $\mathbf{W}$  é realizada com base nas médias entre as matrizes de covariâncias dos sinais de cada classe,  $\mathcal{C}_1$  e  $\mathcal{C}_2$ . Seja a matriz  $\mathbf{C}^{(i)} = \frac{1}{q} \mathbf{X}^{(i)} \mathbf{X}^{(i)T}$ , correspondente a matriz de covariância dos trechos filtrados de sinais, ou seja,  $\mathbf{X}^{(i)}$ . As médias entre as matrizes de covariâncias de cada trecho do sinal são dadas por,

$$\mathbf{C}_1 = \frac{1}{N_1} \sum_{i \in \mathcal{C}_1} \mathbf{C}^{(i)} \quad \text{e} \quad \mathbf{C}_2 = \frac{1}{N_2} \sum_{i \in \mathcal{C}_2} \mathbf{C}^{(i)}, \quad (2)$$

em que  $\mathbf{C}_1$  e  $N_1$  são, respectivamente, a matriz de covariância e o número de exemplos correspondente a classe  $\mathcal{C}_1$  e  $\mathcal{C}_2$  e  $N_2$  para a classe  $\mathcal{C}_2$ .

Os filtros espaciais, via CSP, são obtidos a partir da solução do problema de otimização definido na (Eq. 3),

$$\mathbf{v}^* = \underset{\mathbf{v}}{\text{argmax}} \frac{\mathbf{v}^T \mathbf{C}_1 \mathbf{v}}{\mathbf{v}^T (\mathbf{C}_1 + \mathbf{C}_2) \mathbf{v}}. \quad (3)$$

sendo  $\mathbf{v}$  um vetor coluna.

A solução do problema definido em Eq. (3), é obtida pela Eq. (4),

$$\mathbf{C}_1 \mathbf{v}_j = \lambda_j (\mathbf{C}_1 + \mathbf{C}_2) \mathbf{v}_j \quad (4)$$

em que o vetor  $\mathbf{v}_j$  corresponde aos autovetores generalizados da matriz  $(\mathbf{C}_1 + \mathbf{C}_2)^{-1} \mathbf{C}_1$ , com  $j = 1, \dots, p$ .

Observa-se que com a maximização da função custo utilizada na Eq. (3) obtém-se direções, vetores  $\mathbf{v}$ , que simultaneamente maximizam a variância para a classe  $\mathcal{C}_1$  e minimizam para a classe  $\mathcal{C}_2$ .

Como consequência, para compor os filtros espaciais contidos na matriz  $\mathbf{W}$ , selecionam-se os autovetores  $\mathbf{v}$  associados, respectivamente, aos pares de maiores e de menores autovalores  $\lambda$  da Eq. (4). Por exemplo, sejam os autovalores  $\lambda_j$ , para  $j = 1, \dots, p$ , organizados em ordem crescente de magnitude, tal que  $\lambda_1 < \lambda_2 < \dots < \lambda_p$  e  $\mathbf{v}_j$ ,

os respectivos autovetores. A matriz  $\mathbf{W}$  é formada pelos autovetores  $\mathbf{v}_j$  correspondentes aos  $M$  pares de autovalores  $\{(\lambda_1, \lambda_p)_1, (\lambda_2, \lambda_{p-1})_2, \dots, (\lambda_{\frac{p}{2}}, \lambda_{\frac{p}{2}+1})_M\}$ , para  $M = 1, 2, \dots, \frac{p}{2}$ , com  $M \leq \frac{p}{2}$ .

#### D. Extração e Seleção de Características

Após a filtragem espacial realizada pelo CSP, obtém-se então, novos sinais como resultante da combinação linear dos sinais de EEG filtrados. Como mencionado na seção III-C, apenas  $M$  pares de filtros espaciais são selecionados para formar a matriz  $\mathbf{W}$  na Eq. (1).

Nesse sentido, para formar um vetor de características computa-se a variância dos sinais após a transformação espacial. Obtendo-se vetores que representam os trechos dos sinais filtrados  $\mathbf{X}^{(i)}$  com dimensão inferior a dimensão a quantidade de sinais. Observa-se que a dimensão do vetor de características é  $2M$ , enquanto que a dimensão de  $\mathbf{X}$  é  $p \times q$ , em que  $2M \leq p$ . Logo, o vetor de características é computado pela expressão,

$$\mathbf{y}_i = \frac{\text{diag}(\mathbf{W}^T \mathbf{C}^{(i)} \mathbf{W})}{\text{trace}(\mathbf{W}^T \mathbf{C}^{(i)} \mathbf{W})} \quad (5)$$

em que as funções  $\text{diag}(\cdot)$  e  $\text{trace}(\cdot)$ , extrai e somam apenas os elementos da diagonal principal do argumento, respectivamente. Logo, o vetor  $\mathbf{y}_i$  contém em seus elementos uma versão normalizada da energia dos sinais resultantes da transformação.

Na Eq. (6) é apresentada uma transformação logarítmica, portanto não linear, normalmente adotada para condicionamento dos elementos do vetor de características [].

$$\mathbf{f}_i = \log(\mathbf{1} + \mathbf{y}_i), \quad (6)$$

Nota-se em Eq. (6) que a operação  $\log(\cdot)$  é aplicada a cada um dos elementos de  $\mathbf{y}_i$  acrescidos de uma constante unitária. Portanto,  $\mathbf{1}$  é um vetor cujo todos os elementos são uns.

#### E. Classificação dos Sinais

Uma vez que os sinais de EEG estão representados pelo vetor de características discutido em (6) definido na seção III-D, pode-se realizar a classificação dos sinais. A classificação consiste em atribuir, a partir do vetor de características, os sinais em uma das classes  $\mathcal{C}_1$  ou  $\mathcal{C}_2$ .

O algoritmo por Análise de Discriminantes Lineares (LDA) está entre os mais populares para a classificação de sinais de EEG em ICM-MI [11].

A classificação dos sinais via LDA é realizada ao se projetar o vetor de características em um espaço unidimensional, denominado de espaço de decisão. A projeção via LDA é dada pela Eq. (7),

$$d_i = \mathbf{s}^T \mathbf{f}_i + s_0, \quad (7)$$

em que, para tomar a decisão quanto a classe dos sinais, define-se que para  $d_i > 0$  tem-se classe  $\mathcal{C}_1$ , por outro lado, para  $d_i \leq 0$  tem-se a classe  $\mathcal{C}_2$ . A Eq. (7) define um hiperplano de separação entre as classes  $\mathcal{C}_1$  e  $\mathcal{C}_2$ . O vetor  $\mathbf{s}$  é determinado ao se maximizar a função custo dada em (8),

$$J(\mathbf{s}) = \frac{\mathbf{s}^T \mathbf{R}_\omega \mathbf{s}}{\mathbf{s}^T \mathbf{R}_\ell \mathbf{s}} \quad (8)$$

em que  $\mathbf{R}_\omega$  é a matriz de espalhamento entre as classes  $\mathcal{C}_1$  e  $\mathcal{C}_2$ , enquanto que  $\mathbf{R}_\ell$  é a matriz de espalhamento total intraclasses []. A solução que maximiza a Eq. (8) é dada na Eq. (9).

$$\mathbf{s} = \mathbf{R}_\ell^{-1}(\mathbf{m}_1 - \mathbf{m}_2), \quad (9)$$

na qual  $\mathbf{m}_1$  e  $\mathbf{m}_2$  são os vetores de características médios para cada uma das classes  $\mathcal{C}_1$  e  $\mathcal{C}_2$ , respectivamente.

#### F. Avaliação de Desempenho

Nesta etapa, utilizou-se, primeiramente, a acurácia, a qual é uma medida efetiva do desempenho de sistemas de ICC. No entanto, ela não considera aspectos de sensibilidade, especificidade e seletividade, relacionando somente o número de exemplos corretamente classificados  $\mathcal{P}_c$ , com o número total de exemplos realizados  $\mathcal{P}_t$  durante um experimento, como mostra em (10).

$$\mathcal{A}_C(\%) = \frac{\mathcal{P}_c}{\mathcal{P}_t} 100 \quad (10)$$

Além da acurácia, observou-se o desempenho da classificação através da matriz de confusão, que demonstra quantas instâncias da base de dados utilizada são classificadas corretamente pelo modelo construído (representados na diagonal principal da matriz) sendo que as outras são classificadas incorretamente [29].

No problema de decisão binária, denomina-se uma classe como positiva e a outra como negativa, desta forma, a matriz de confusão indica quatro possibilidades de acertos e de erros do classificador [30].

A Matriz apresenta os seguintes elementos: Verdadeiros positivos (TP): quando a instância “Positivo” for predita pelo classificador como “Positivo”; Falsos negativos (FN): quando a instância “Positivo” for predita pelo classificador como “Negativo”; Verdadeiros negativos (TN): quando a instância “Negativo” for predita pelo classificador como “Negativo”; Falsos positivos (FP): quando a instância “Negativo” for predita pelo classificador como “Positivo”.

O conjunto VP e VN agrupa os acertos do sistema ICC, enquanto que FN e FP agrupam os erros. Em seguida, são calculadas métricas de desempenho de acordo com os grupos formados:

$$\mathcal{A}_C = \frac{VP + VN}{VP + VN + FN + FP} \quad (11)$$

A Eq. 11 expressa a taxa de acerto global do sistema ICC, ou seja, o número de acertos dividido pelo número total de tentativas.

#### IV. RESULTADOS

Os sinais de EEG coletados são organizados em duas sessões:  $SS1$  e  $SS2$ . As sessões são utilizadas, de forma alternada, para o treinamento e a avaliação do sistema ICM. Durante o treinamento os parâmetros livres (o CSP e o LDA) do sistema ICM são determinados. Enquanto que durante a avaliação, o desempenho do sistema é aferido com base na acurácia de classificação.

Os resultados estão organizados em uma sequência com cinco blocos. No primeiro bloco, os resultados consistem em confrontar dois cenários, com e sem um banco com doze filtros temporais. Nesses cenários os oito canais são utilizados.

Nos demais blocos de resultados, considera-se que apenas um subconjunto de canais está disponível. Por exemplo, apenas o canal  $C_z$ , ou ainda, apenas os canais  $C2$  e  $C3$ , assim por diante.

No segundo bloco de resultados, a análise de cada canal é realizada. Nesse bloco, apenas o banco com doze filtros é utilizado para em seguida entregar os sinais ao CSP e ao LDA.

No terceiro e no quarto de resultados estão os resultados obtidos quando os sinais de EEG são agrupados dois a dois e três a três, respectivamente.

No quinto e último bloco de resultados, são apresentados os resultados obtidos ao combinar os sinais de EEG quatro a quatro e uma comparação das médias dos melhores canais por bloco de resultados é apresentada.

##### A. Primeiro bloco de resultados

Neste bloco, os resultados são obtidos para o cenário  $a)$  em que a faixa de frequência  $\Delta f$  é definida como o intervalo entre 6Hz à 32Hz; e o cenário  $b)$  em que  $\Delta f$  é sub-dividida em faixas  $\delta f$  com largura de 4 Hz. Cada faixa de frequência  $\delta f$  apresenta uma sobreposição de 50% entre si e totaliza 12 faixas. Em ambos os cenários 03 pares de filtros espaciais são adotados.

Os resultados de acurácia para ambos os cenários e alternando as sessões para o treinamento e a avaliação da ICM são apresentados na Tabela I.

Table I  
ACURÁCIAS PARA OS CENÁRIOS (A) E (B) AO CONSIDERAR OS CONJUNTOS DE DADOS  $SS1$  E  $SS2$ .

| CENÁRIOS | SS1 - SS2 | SS2 - SS1     |
|----------|-----------|---------------|
| a)       | 83,32%    | <b>89,59%</b> |
| b)       | 91,19%    | <b>93,70%</b> |

##### B. Segundo bloco de resultados

Os resultados apresentados nesta seção são obtidos quando cada um dos canais é avaliado individualmente. A faixa de frequências  $\Delta f$  é subdividida em  $K$  faixas de largura  $\delta f$ . A

faixa  $\Delta f$  corresponde ao intervalo entre 6 à 32Hz,  $\delta f$  é 4Hz e  $K = 12$ .

Na análise individual de cada canal, a maior acurácia é obtida para o canal  $C_2$ , em que obtém-se a média de 67,37% de acurácia entre as sessões  $SS1$  e  $SS2$ . A menor acurácia é obtida quando o canal  $C_3$  é utilizado. Nesse caso, obtém-se 50,2% de acurácia média.

A média entre os resultados de todos os canais encontrada é de 58,19% ao considerar os dados das duas sessões. Na Figura 3 são apresentadas as taxas de acurácia média obtida em cada canal para as sessões  $SS1$  e  $SS2$ .

O resultado da figura 3 tem correlação com a divisão do cérebro por hemisférios, pois a visualização e a imaginação são atividades predominantes do lado direito do cérebro. Por isso, espera-se que o lado direito venha a ser recorrente, pois a imagética motora está relacionada à imaginação e a tarefa para estimulá-la requer uma atividade experimental que geralmente é feita a partir de dicas que podem ser “visualizadas” na tela do computador, estimulando assim, a visualização que se refere a linguagens não verbais, ou seja, imagens [2], [34].

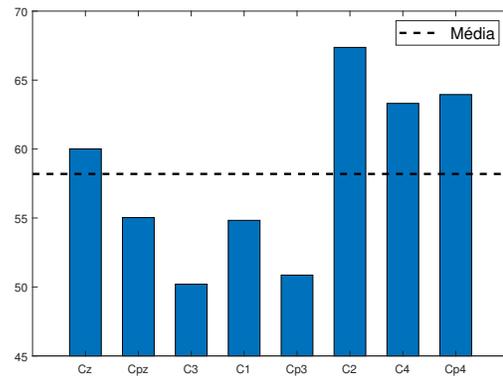


Figure 3. As barras indicam as acurácias médias entre as sessões  $SS1$  e  $SS2$  para cada canal. A linha tracejada representa o valor média das acurácias de 58,19%.

##### C. Terceiro bloco de resultados

No terceiro bloco de resultados, considera-se que apenas dois canais por vez estão disponíveis. Nesse caso, a maior acurácia média é obtida para a combinação que relaciona o canal  $C_2$  atingindo-se o valor de 74,44%.

Ao combinar os canais dois a dois é possível observar uma elevação na acurácia média geral da ICM em relação aos resultados apresentados na Figura 3.

As combinações dos canais são visualizadas nas Figuras 4 e 5, onde os resultados são apresentados no formato de diagrama de caixas. Ao analisar os dois diagramas, nota-se que apesar do canal Cp4 possuir valores máximos e mediana maiores que o canal C2 na figura 4, na 5 esses resultados são invertidos, onde o canal C2 passa a possuir uma mediana bem maior que a do canal Cp4. Portanto, ao combinar as duas sessões a média geral para o canal C2 é superior a média do canal Cp4.

Na Figura 4 observa-se dois valores discrepantes nos muito superior que acaba por destoar dos restantes dos dados, assim como no canal  $C3$ , porém, neste caso, o valor passa a ser muito inferior. Na Figura 4 é apresentado a análise dos canais ao utilizar os dados da sessão  $SS2$  para a medição da acurácia do sistema.

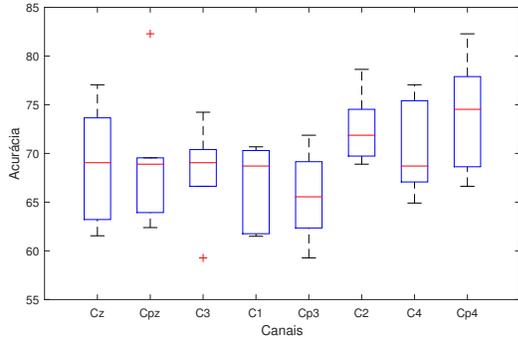


Figure 4. Diagrama de caixas para os resultados obtidos pela combinação de canais dois a dois. Utiliza-se a sessão  $SS1$  para treinamento e a sessão  $SS2$  para avaliação da ICM e cálculo da acurácia.

Na Figura 5 são apresentados os resultados para a utilização os dados da sessão  $SS1$  para a medição da acurácia do sistema.

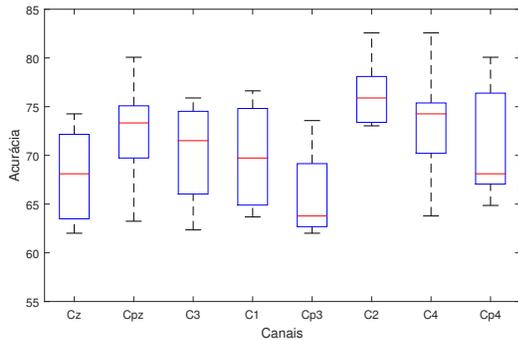


Figure 5. Diagrama de caixas para os resultados obtidos a partir da combinação de canais dois a dois. Utiliza-se a sessão  $SS2$  para treinamento e a sessão  $SS1$  para a avaliação da ICM e cálculo da acurácia

#### D. Quarto bloco de resultados

Neste bloco de resultados os canais são combinados três a três. Na Figura 6 são apresentados os resultados para a combinação dos canais  $C2$ ,  $C4$  e  $Cp4$  (que obtém taxas de acurárias médias, proveniente das combinações com os outros sete canais, de 74, 44%, 72, 03% e 72, 29%, respectivamente) e os canais  $Cz$ ,  $C1$  e  $Cp3$  (que obtém taxas de acurárias médias, proveniente das combinações com os outros sete canais, de 68, 26%, 68, 15% e 65, 94%, respectivamente).

Com base na Figura 6 é possível observar que mesmo ao utilizar os canais que produzem os menores desempenhos é possível alcançar taxas de acurácias médias, superiores aos canais que geram melhores desempenhos das Figuras 4 e 5. Essas taxas são alcançadas ao combinar um terceiro canal aos canais das Figuras 4 e 5.

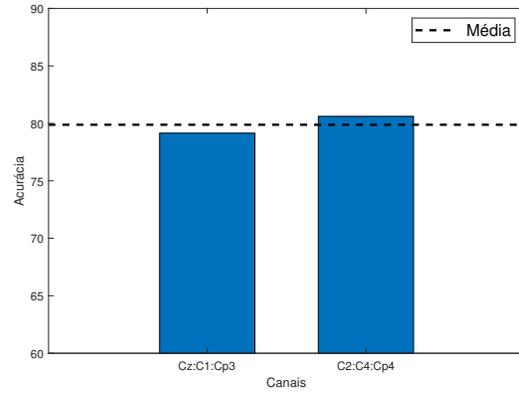


Figure 6. Análise das taxas de acurácias para os três canais com os maiores e menores desempenhos em relação as combinações de canais dois a dois.

#### E. Quinto bloco de resultados

O quinto bloco de resultados gerados resultam da combinação dos 4 canais ( $Cp3$ ,  $C1$ ,  $Cz$ ,  $C3$ ) com menores taxas de acurácia e dos 4 canais ( $Cpz$ ,  $C2$ ,  $C4$  e  $Cp4$ ) com as maiores taxas de acurácia, onde as taxas médias de acurácia obtidas são de 85, 96% e 87, 12%, respectivamente. As taxas de acurácia da combinação de três canais é ilustrada na Figura 7.

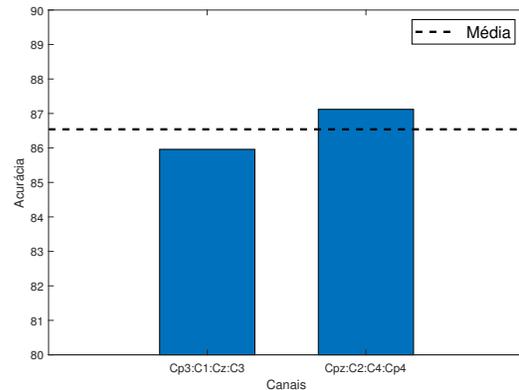


Figure 7. Análise das taxas de acurácias para os quatro canais com os maiores e menores desempenhos em relação as combinações de canais dois a dois.

Para finalizar esta seção as melhores taxas médias de acurácias obtidas nos blocos de resultados são demonstradas na Figura 8.

Com isso, as discussões a respeito dos resultados são comentadas na próxima seção.

### V. CONCLUSÕES

Com base nos resultados conclui-se que ao se utilizar o banco de filtros o desempenho do sistema ICM atinge melhores resultados. Destaca-se os fatores que proporcionam o melhor desempenho são a adição de 12 novos sinais filtrados por canal nas sub-bandas de 6 a 32Hz. A distinção de

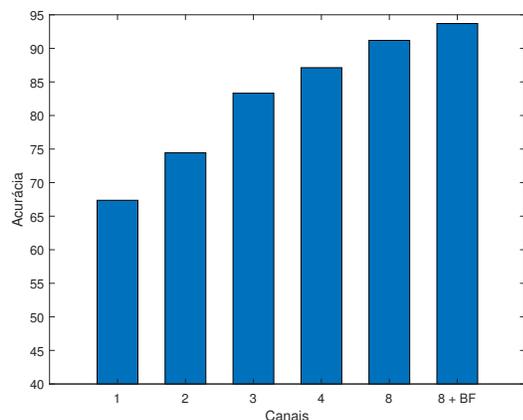


Figure 8. Demonstrativo da média de todos os bloco de resultados. Para 1 até 4 são considerados os valores da análise do canais individualmente. Para 8 é demonstrado o resultado dos oito canais com apenas um filtro de 6 a 32 Hz e para 8 + BF são os oito canais com um banco de doze filtros.

características nas sub-faixas de frequência separadamente é facilitado pelo uso do banco de filtros, pois pode-se observar fenômenos e aspectos que não são observados ao utilizar apenas um filtro temporal com frequências de corte de 6 a 32Hz.

Ao combinar os canais pode-se observar uma melhora geral na acurácia média de todas as combinações quando comparado ao sinal de referência. Este fator pode ser justificado devido as médias dos melhores canais que ao combinar com as médias dos canais menores, eleva a taxa de acertos geral do sistema. O mesmo pode ser observado ao combinar os canais três a três e quatro a quatro.

## REFERENCES

- [1] L. F. Nicolas-Alonso e J. Gomez-Gil, "Brain Computer Interfaces, a Review," *Sensors (Basel)*, vol. 12, pp.1211-79, Jan. 2012.
- [2] T. Lopes, *Estudo, implementação e comparação de diferentes tipos de pré-processamento aplicados a um sistema cérebro-computador*. Monografia, Universidade Federal do Pará, 2019.
- [3] S. Abdulkader e A. Atia e M. Mostafa, "Brain computer interfacing: Applications and challenges," *Egyptian Informatics Journal*, vol. 16, pp. 213-230, jul. 2015.
- [4] D. J. McFarland e J. R. Wolpaw, "Brain-Computer Interface Operation of Robotic and Prosthetic Devices," *Elsevier*, vol. 79, pp: 169-186, Mar. 2010.
- [5] G. B. Bernardi, *Ferramenta Simplificada Para Testes de Algoritmos de Seleção das características e Classificação em Sinais Cerebrais Captados com EEG para BCIs baseados em Imagética Motora*, Dissertação (mestrado), Universidade Federal de Itajubá, 2018
- [6] Y. Vaz, *Extração de características para a classificação de imagética motora em interfaces cérebro-computador*, Dissertação (mestrado), Universidade de São Paulo, 2016.
- [7] T. A. Tavares, "Efeito das técnicas de filtragem espacial no desempenho de sistemas BCI-SSVEP: um estudo de caso", Monografia, Universidade Federal de Ouro Preto, 2017.
- [8] J. Sanei e A. Chambers, "EEG Signal Processing", John Wiley Sons Ltd, sep. 2007;
- [9] K. K. Ang e Z. Y. Chin e C. Wang e C. Huan e H. Zhang, "Filter bank common spatial pattern algorithm on BCI competition IV Datasets 2a and 2b", *Frontiers in neuroscience*, vol. 6, mar. 2012.

- [10] J. C. Machado, "Pré-processamento, extração de características e classificação offline de sinais eletroencefalográficos para uso em sistemas bci", Dissertação (mestrado), Universidade Federal do Rio Grande do Sul, 2012.
- [11] F. Lotte e M. Congedo e A. Lécuyer e F. Lamarche e B. Arnaldi, "A review of classification algorithms for EEG-based brain-computer interfaces," *Journal of Neural Engineering*, vol. 15(3), abr. 2018.
- [12] M. Tangermann e K. Müller e A. Aertsen e N. Birbaumer e C. Braun e C. Brunner e R. Leeb e C. Mehring e K. Müller e G. Müller-Putz e G. Nolte e G. Pfurtscheller e H. Preissl e G. Schalk e A. Schlögl e C. Vidaurre e S. Waldert e B. Blankertz, "Review of the BCI competition IV," *Frontiers in neuroscience*, v.6, pp. 55, jul. 2012.
- [13] A. Jiang e Q. Wang e J. Shang e X. Liu, "Sparse Common Spatial Pattern for EEG Channel Reduction in Brain-Computer Interfaces," *IEEE 23rd International Conference on Digital Signal Processing (DSP)*, Shanghai, China, pp. 1-4, 2018
- [14] M. Arvaneh e C. Guan e K. K. Ang e A. T. E. Ward e K. S. G. Chua e C. W. K. Kuah e G. J. E. Joseph e K. S. Phua e C. Wang, "Facilitating motor imagery-based brain-computer interface for stroke patients using passive movement," *Neural Computing and Applications*, 2016.
- [15] S. Haghypour e N. M. Firouz, "A Survey on EEG Signal Classification with Neural Network for Brain Computer Interface Applications," *Inte. J. of Comp. info. Tech. (IJOCIT)* vol. 4, pp55-62, mai. 2016.
- [16] Cyton Biosensing Board (8-channels), [https://docs.openbci.com/Hardware/02-Cyton\\_Openbci](https://docs.openbci.com/Hardware/02-Cyton_Openbci), maio 2019.
- [17] R. Duarte, *Universidade Federal de Santa Catarina*, "Low cost Brain Computer Interface system for AR.Drone Control," jun. 2017.
- [18] K. K. Ang e Z. Y. Chin e H. Zhang e C. Guan, "Mutual information-based selection of optimal spatial-temporal patterns for single-trial EEG-based BCIs," *Pattern Recognition*, vol. 45, pp. 2137-2144, jun. 2012.
- [19] F. Lotte, "A tutorial on EEG signal-processing techniques for mental state recognition in brain-computer interfaces," *Guide to Brain-Computer Music Interfacing*, out. 2014.
- [20] S. Ge e R. Wang e D. Yu, "Classification of Four-Class Motor Imagery Employing Single-Channel Electroencephalography," *PLoS ONE*, vol. 9, pp. e98019, jun. 2014.
- [21] T. Alotaiby e F. E. A. El-Samie e S. A. Alshebeili e I. Ahmad, I., "A review of channel selection algorithms for EEG signal processing," *EURASIP Journal on Advances in Signal Processing*, vol. 2015, ago. 2015.
- [22] Y. Li e Y. Koike, "A real-time BCI with a small number of channels based on CSP", *Neural Computing and Applications*, nov. 2010.
- [23] M. Arvaneh e C. Guan e K. K. Ang e C. Quek, "Optimizing the Channel Selection and Classification Accuracy in EEG-Based BCI," *IEEE Transactions on Biomedical Engineering*, vol. 58, pp. 1865-1873, jul. 2011.
- [24] L. He e Z. Yu e Z. Gu e Y. Li, "Bhattacharyya bound based channel selection for classification of motor imageries in EEG signals," *Proceedings of Chinese Control and Decision Conf.*, pp. 2353-2356, jun. 2009.
- [25] Y. Yang e O. Kyrgyzov e J. Wiart e I. Bloch, "Subject-specific channel selector for classification of motor imagery electroencephalographic data," *Proceedings of the 38th Int'l Conf. on Acoustics, Speech, and Signal Processing*, pp. 1277-1280, mai. 2013.
- [26] M. Li e J. Ma e S. Jia, "Optimal combination of channels selection based on common spatial pattern algorithm," *Proceedings of the IEEE Int'l conf. on Mechatronics and Automation*, ago. 2011.
- [27] M. R. Zimbric e C. M. Sharpe e K. C. Albright e M. P. Nespeca, "Three-channel electroencephalogram montage in neonatal seizure detection and qualification," *Pediatr. Neurol*, 2011.
- [28] T. N. Lal e M. Schröder e T. Hinterberger e J. Weston e M. Bogdan e N. Birbaumer e B. Schölkopf, "Support vector channel selection in BCI," *IEEE Trans. Biomed. Eng.*, *IEEE Transactions on Biomedical Engineering*, vol. 51(6), pp.1003-1010, jun. 2004.
- [29] J. D. A. Silveira, "Análise de sinais cerebrais utilizando árvores de decisão.", Dissertação (mestrado), Universidade Federal do Rio Grande, FURG, 2013.
- [30] C. D. Silva, "Reconhecimento de padrões em sinais de EEG para detecção de intenção de movimento para aplicação em interface cérebro-máquina.", Tese (doutorado), Universidade Federal de Santa Catarina, Santa Catarina, 2017.
- [31] Leeb, R. e Lee, F. e Keinrath, C. e Scherer, R. e Bischof, H. e Pfurtscheller, G. "Brain-computer communication: Motivation, aim, and

- impact of exploring a virtual apartment,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 15, n. 4, p.473–482, 2007.
- [32] C. Brunner, R. Leeb, G. Muller-Putz, A. Schlogl, and G. Pfurtscheller, “Bci competition 2008–graz data set a,” Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces), Graz University of Technology, pp. 136–142, 2008.
- [33] FOX, Stuart Ira. *Human physiology*. 12a ed. McGraw-Hill (2011).
- [34] GUITON E HALL. *Tratado de Fisiologia Médica*. 12ª Edição. Elsevier Editora, 2011.