

Towards ideal time window for classifying motor imagery in brain-computer interfaces

V. M. Vilas-Boas, V. da S. Jorge, C. D. Silva

Universidade Federal do Pará, Brazil

vitormendesvilasboas@gmail.com, vitor.dsilvajorge@gmail.com, cleison@ufpa.br

Abstract. Brain-Computer Interfaces (ICM) allow the control of devices by modulating brain activity. Commonly, when based on motor imagery (IM) these systems use the energy (de)synchronization in the electroencephalogram signal (EEG), voluntarily caused by the individual, to identify and classify their motor intention. Therefore, the EEG segment used in the training of the learning algorithms plays a fundamental role in the description of the characteristics and, consequently, in the recognition of patterns in the signal. In this context, the objective of this work is to demonstrate the correlation between the temporal properties of the input EEG segment and the classification performance of a ICM-IM system. An auxiliary sliding window was used in order to obtain the variation of performance in function of the variation in the time and to support the decision making about the appropriate window. Simulations based on public EEG data point to significant variability in the location and width of the ideal window and suggest the need for individualized selection according to the cognitive patterns of each subject.

CCS Concepts: • **Computing methodologies** → **Machine learning**.

Keywords: brain-computer interfaces, ideal time window, machine learning, motor imagery

1. INTRODUÇÃO

Uma Interface Cérebro-Máquina (ICM) permite o controle de dispositivos diretamente pelo cérebro por meio da coleta, do processamento e da tradução dos padrões da atividade neuronal em mensagens ou comandos [Clerc et al. 2016]. Dentre os paradigmas ICM disponíveis, a Imagética Motora (IM) baseia-se na decodificação do fenômeno de (De)Sincronização da atividade elétrica cortical (ERS/ERD) associado a tarefas motoras específicas (simulação mental do movimento das mãos, pés e língua, por exemplo) e que são comumente registradas por eletroencefalografia (EEG) [Pfurtscheller and Neuper 2001][Wolpaw et al. 2002].

A intenção motora do indivíduo é traduzida a partir da variação de energia dos sinais de EEG. Para decodificá-la define-se duas fases de aprendizado supervisionado, que são organizadas de maneira sequencial para realizar o ajuste e a avaliação dos algoritmos [Graimann et al. 2010]. Assim, segmentos de sinais de EEG são utilizados como entrada para a cadeia de processamento que, em sua forma mais tradicional, é composta por três sub-sistemas: o de filtragem temporal e espacial, de extração e seleção de características e, finalmente, o de classificação dos sinais de EEG [Lotte 2014].

Ainda assim, apesar dos algoritmos que compõem o sistema ICM-IM serem altamente sensíveis à faixa de frequência dos sinais adotada e, também, dos segmentos de tempo utilizados durante o ajuste dos parâmetros dos algoritmos, é comum que os argumentos que definem as janelas de sinais de EEG utilizadas para extração das características sejam definidos de forma empírica e independentemente do usuário envolvido [Xu et al. 2014]. Essa constatação torna a definição da janela do sinal de EEG uma etapa importante, ainda na fase inicial. Sendo que a definição arbitrária, tanto da largura

Copyright©2020 Permission to copy without fee all or part of the material printed in KDMiLe is granted provided that the copies are not made or distributed for commercial advantage, and that notice is given that copying is by permission of the Sociedade Brasileira de Computação.

quanto da localização da janela de sinais em relação à instrução apresentada durante a coleta podem comprometer o desempenho e a generalização do sistema [Feng et al. 2018].

Nesse sentido, este artigo busca aplicar os conceitos de Mineração de Dados no contexto de sistemas ICM-IM de forma a correlacionar a variação do desempenho em função da localização e da largura da janela de EEG e, com isso, descobrir a janela que melhor descreve a intenção motora do indivíduo. Por se tratar de uma grande massa de dados geradas por indivíduo a distinção de características discriminantes não é um processo trivial, o que, a primeira vista torna o processo de descoberta de conhecimento em conjuntos de dados (KDD) potencialmente útil na identificação de padrões no sinal e especificamente do segmento de EEG indicado à determinado sujeito. Um conjunto de dados públicos de EEG é utilizado para validar a abordagem proposta.

Neste artigo, letras maiúsculas e minúsculas em negrito indicam matrizes e vetores, respectivamente, ao passo que letras em itálico denotam escalares. O símbolo \mathbb{R} corresponde ao conjunto dos números reais enquanto $\mathbb{R}^{N \times M}$ denota o conjunto de matrizes reais de dimensão $N \times M$.

2. DESCOBERTA DE CONHECIMENTO APLICADA À ICM-IM

A descoberta de conhecimento em dados (KDD, sigla em inglês para *Knowledge-Discovery in Databases*) é definida como um processo iterativo para identificação de padrões compreensíveis e extração de informações previamente desconhecidas e potencialmente úteis em grandes conjuntos de dados [Fayyad et al. 1996]. De forma análoga ao KDD, o processamento de sinais de EEG em sistemas ICM-IM também baseia-se na descoberta de padrões em um volume expressivo de dados a fim de extrair conhecimento acerca da intenção motora do indivíduo. O EEG permite a coleta de sinais com alta resolução temporal o que comumente resulta em conjuntos de dados volumosos organizados em arquivos distintos que mantêm as informações da atividade elétrica cerebral dos sinais obtidos nos canais de EEG utilizados em forma de dados e meta-dados.

Em sistemas ICM-IM típicos, esses sinais são coletados a partir de um protocolo experimental baseado em estímulos visuais que orienta os indivíduos na realização de tarefas mentais específicas para modulação da atividade cerebral [Pfurtscheller and Neuper 2001]. Os sinais, relativos aos vários canais de EEG dispostos no escalpo, são amostrados em uma dada frequência F_s , comumente definida pelo equipamento utilizado na coleta.

As marcações correspondentes aos eventos nas N iterações do protocolo experimental, efetuadas ao longo da coleta, podem ser utilizadas para extrair múltiplos segmentos de EEG associados à ocorrência de MI do conjunto completo de dados. Tais segmentos são janelas menores de sinais de EEG, tipicamente denominadas de épocas, as quais, em geral, são extraídas dos trechos de sinais coletados enquanto espera-se que o usuário esteja realizando uma tarefa motora específica, orientado pela instrução visual apresentada. O momento em que a instrução é apresentada ao usuário é, portanto, um referencial importante para extração das épocas de EEG. As duas propriedades que as definem na dimensão do tempo, largura e localização, são definidas em relação ao momento da instrução visual em cada ensaio.

Normalmente, a janela de EEG subtraída está localizada mais próxima à dica, com base no suposto de que nesse momento o estado de engajamento do indivíduo para realização da tarefa desejada é máximo. Apesar da variabilidade da atividade cerebral inter-indivíduos e as características não estacionárias dos sinais de EEG, é comum que as épocas sejam delimitadas por janelas temporais arbitrárias e únicas, independentemente do sujeito [Feng et al. 2018]. A Figura 2 ilustra uma janela de EEG tipicamente usada na literatura bem como sua projeção em relação ao protocolo experimental adotado na coleta dos dados públicos de EEG utilizados neste trabalho.

Neste artigo utilizam-se as heurísticas de mineração de dados na busca de padrões nos sinais de EEG associados à duas classes de imagéticas motoras (IM): a IM da mão direita (MD) e da mão esquerda

(ME), respectivamente. A abordagem visa realizar uma análise individualizada dos possíveis segmentos de sinais de EEG durante a realização da tarefa mental de modo a correlacionar as propriedades de largura e de localização da janela correspondente com o desempenho final de classificação.

Como forma de conectar as etapas que compõem o processo de KDD com a cadeia de processamento básica de sistemas ICM-IM, o diagrama apresentado na Figura 1 descreve o modelo proposto para identificação da janela de EEG ideal conforme os sinais particulares de cada indivíduo disponíveis em um conjunto de dados públicos de EEG.

Fig. 1. Modelo para descoberta de conhecimento aplicado ao janelamento ideal de sinais de EEG em sistemas ICM-IM



Nota-se que a sequência apresentada na Figura 1 remetem às etapas do processo de KDD. Ao final de cada etapa, as transformações sequenciais realizadas nos dados visam aprimorar os sinais de EEG e ressaltar características que permitam a classificação entre as classes de IM envolvidas. Cada etapa é descrita com mais detalhes nas seções subsequentes.

3. PROCEDIMENTOS METODOLÓGICOS

O conjunto de dados 2a da Competição IV de ICM [Brunner et al. 2008] foi utilizado na análise. Os dados incluem sinais de EEG de 9 sujeitos enquanto realizavam 4 tarefas de IM (mão esquerda, mão direita, pés e língua). Os sinais foram coletados de $P = 22$ canais de EEG e 3 canais de Eletrooculograma (EOG), a uma taxa de amostragem $F_s = 250Hz$. Duas sessões de coleta foram disponibilizadas em dois subconjuntos, cada qual contendo 72 ensaios por tarefa, totalizando 288 ensaios por sessão.

O escopo do estudo foi delimitado para contemplar apenas tarefas de IM da mão esquerda (ME) e mão direita (MD). Para tanto, as bases de dados de cada indivíduo foram submetidas à uma fase de pré-processamento a fim de se obter uma nova representação a partir da limpeza, normalização, seleção e concatenação dos dados.

3.1 Pré-Processamento

Em consonância com a etapa correspondente do processo de mineração, a primeira fase da análise consiste em preparar os dados a fim de possibilitar a classificação efetiva de IM. Primeiramente, valores nulos são corrigidos utilizando interpolação linear. Em seguida, os sinais nos canais de EOG foram descartados e os 22 canais de EEG remanescentes definem as variáveis do problema. As meta-informações parametrizaram a limitação e dos ensaios ao período de IM no protocolo de coleta e os rótulos indicando as tarefas de IM foram usados para extrair apenas ensaios de MD e ME nas duas

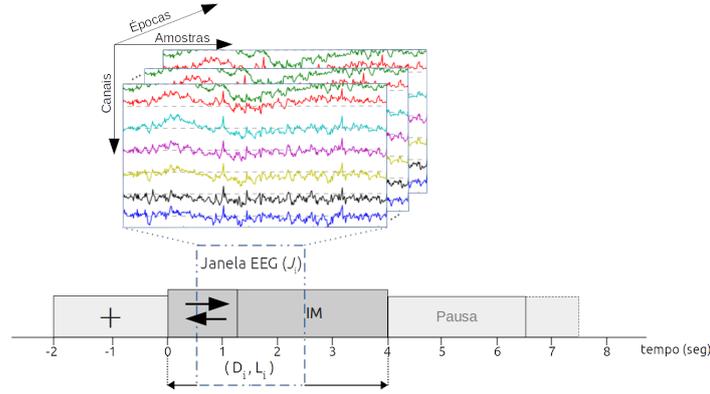


Fig. 2. Extração de épocas de EEG com base no par de argumentos que definem uma janela temporal J_i para $i \in \{1, 2, \dots, K\}$. A linha tracejada representa um exemplo de janela típica utilizada da literatura projetada no protocolo experimental utilizado na coleta de dados adotado. Nota-se que, a janela típica está localizada à $D = 0.5$ segundos após a apresentação da dica visual com $L_i = 2$ segundos de largura.

bases de cada indivíduo. Por fim, os 144 segmentos de EEG por base, sendo 72 por tarefa, foram encadeados para se obter uma base única com 288 segmentos.

3.2 Janelamento

O processo de segmentação dos sinais de EEG, também denominado de extração de épocas, comumente se dá com a obtenção de janelas dispostas entre dois marcos temporais, aqui denotados por T_{min} e T_{max} , que correspondem, respectivamente, ao momento da apresentação da instrução visual e ao início da pausa curta que encerra o tempo estipulado para realização da tarefa em cada ensaio.

Janelas extraídas nesse intervalo temporal contemplam as amostras no segmento $\{A_-, A_+\}$, cujos extremos são determinados por dois argumentos, D e L , sendo $A_- = F_s(T_{min} + D)$ e $A_+ = F_s(T_{min} + D + L)$. Juntos, os valores atribuídos a ambos os argumentos definem a localização (D) e a largura (L) da janela no tempo em relação a T_{min} , respectivamente, de forma a satisfazer a relação $T_{max} \geq L \geq D + 1$ com $D \geq T_{min}$.

Seja J_i uma janela temporal definida por um par de argumentos (D_i, L_i) , ao combinar cada localização $D_i = T_{min}(\frac{\delta_i}{2})$, $\forall \delta_i \in \{0, 1, 2, \dots, T_{max} - 1\}$ com cada elemento do conjunto relativo de larguras $L \in \{D + 1, D + 1.5, \dots, T_{max} - D\}$ obtém-se K possíveis janelas temporais no intervalo $\{T_{min}, T_{max}\}$. Nota-se que $i = 1, 2, \dots, K$.

Considerando o conjunto de dados adotado, cujo protocolo de coleta também é ilustrado na Figura 2, observa-se um intervalo de 4 segundos destinado à realização da tarefa motora em cada ensaio. Ao assumir que a origem dos ensaios se dá no momento em que a instrução visual é apresentada, têm-se $T_{min} = 0$ e $T_{max} = 4$ e, portanto, o tempo para realização da tarefa motora corresponde a um total de 1000 amostras para a frequência de amostragem $F_s = 250\text{Hz}$. Neste caso, $K = 28$ janelas podem ser definidas com base no intervalo de interesse, conforme apresentado na Figura 2.

Definidas as possíveis janelas temporais, estas são usadas para extração de épocas dos segmentos obtidos no pré-processamento. As etapas de processamento subsequentes à fase de janelamento são executadas de maneira iterativa com base nas 288 épocas extraídas de cada uma das K janelas definidas, a fim de se obter o desempenho de classificação em função dos argumentos que as definem.

Para corroborar com uma das principais propriedades de sistemas ICM-IM, cujo problema de classificação, em geral, enquadra-se na categoria de aprendizado supervisionado, as épocas contribuem para que o processamento ocorra em duas fases sequenciais, usualmente denominadas por treinamento

e validação [Nicolas-Alonso and Gomez-Gil 2012].

Cada época é denotada pela matriz $\mathbf{Z} \in \mathbb{R}^{P \times Q}$, cujas dimensões referem-se aos P canais e suas Q amostras no intervalo $\{A_-, A_+\}$ e associada à instrução visual apresentada no ensaio correspondente por um rótulo t indicando o tipo de tarefa motora esperada do usuário. Assim, sejam Ω_1 e Ω_2 classes que representam as tarefas de ME e MD, respectivamente. O valor atribuído ao rótulo t associa cada época à classe correspondente, sendo $t = 1$ para classe Ω_1 e $t = 2$ para classe Ω_2 .

As épocas contribuem para que o processamento ocorra nas duas fases sequenciais [Nicolas-Alonso and Gomez-Gil 2012]. Primeiro, os algoritmos são treinados com base em um sub-conjunto com N_T épocas, denotado por \mathcal{E}_T , e seus respectivos rótulos \mathbf{t}_T . Na fase posterior, a validação do sistema devidamente calibrado ocorre a partir das N_V épocas sobressalentes, \mathcal{E}_V , e rótulos \mathbf{t}_V . Nota-se que $\mathcal{E}_T \cap \mathcal{E}_V = \emptyset$ e $N = N_T + N_V$.

3.3 Filtragem Temporal

Os sinais de EEG possuem baixa relação sinal ruído e portanto são suscetíveis à diversos tipos de ruídos e artefatos [Teplan 2002]. Além dos biopotenciais cerebrais, biopotenciais associados a outras partes do corpo são capturados, como batimentos cardíacos ou movimento muscular da cabeça. Oscilações de impedância no posicionamento dos eletrodos e ruídos de rede também tornam o sinal de EEG ruidoso do ponto de vista de sistemas ICM-IM [Minguillon et al. 2017].

Uma vez que esses ruídos estão representados em amplitudes e frequências mais altas em relação aos ritmos da atividade elétrica cerebral [Teplan 2002], a etapa de filtragem temporal visa atenuar sua interferência nos sinais de interesse como forma de delimitar a informação espectral a uma faixa de frequência específica relacionada à ocorrência de IM [Urigüen and Garcia-Zapirain 2015].

Nesse sentido, um filtro digital passa-faixa de Resposta Impulsiva Infinita (IIR) de 5ª ordem é adotado neste estudo e aplicado em cada época de EEG, $\mathbf{Z} \in \mathbb{R}^{P \times Q}$, obtendo-se a versão filtrada dos sinais, $\mathbf{X} \in \mathbb{R}^{P \times Q}$, na faixa de frequência entre 8 e 30Hz. As frequências nessa faixa são tipicamente associadas ao fenômeno de IM e correspondem aos ritmos da atividade cerebral μ e β [Neuper and Pfurtscheller 2001].

3.4 Extração de Características

O fenômeno que descreve a tarefa motora, em geral, ocorre de forma contralateral no cérebro, sendo tarefas de MD perceptíveis no hemisfério esquerdo e tarefas de ME no hemisfério direito. Com isso, a localização desse fenômeno no escalpo, refletido na amplitude do sinal nos canais de EEG, é comumente obtido com uma filtragem espacial que subsidia a extração das características que descrevam MI em forma de energia [Clerc et al. 2016]. Para tal, o algoritmo Padrões Espaciais Comuns (CSP) é um dos algoritmos populares em sistemas ICM-IM [Ramoser et al. 2000].

O CSP busca filtros espaciais que maximizam a variância de energia de uma classe e minimizam a de outra classe de forma a ressaltar as características que descrevem a IM [Lotte 2014]. Ao considerar os N_κ sinais filtrados, \mathbf{X} , para o conjunto \mathcal{E}_T associadas à classe Ω_κ , um filtro espacial $\mathbf{w} \in \mathbb{R}^{P \times 1}$, que maximiza a separabilidade entre as classes Ω_1 e Ω_2 pode ser obtido extremado:

$$\arg_{\mathbf{w}} \max \frac{\mathbf{w}^T \mathbf{C}_1 \mathbf{w}}{\mathbf{w}^T (\mathbf{C}_1 + \mathbf{C}_2) \mathbf{w}}, \quad (1)$$

em que o sobrescrito $(\cdot)^T$ denota transposição matricial, \mathbf{C}_1 e \mathbf{C}_2 representam as médias entre as matrizes de covariância espacial das duas classes, respectivamente.

Uma possível solução para a Eq.(1), é obtida ao resolver $\mathbf{C}_1 \mathbf{w} = \lambda (\mathbf{C}_1 + \mathbf{C}_2) \mathbf{w}$, em que λ e \mathbf{w} correspondem aos autovalores e autovetores generalizados, respectivamente. O problema de autovetores generalizados gera na equação P filtros $\mathbf{w}^{(j)}$ para $j = 1, 2, \dots, P$, cada qual, ao ser aplicado na matriz

de entrada, produz o sinal espacialmente filtrado. Ao considerar os P filtros espaciais, um vetor de características pode ser definido por, $\boldsymbol{\rho} = \log(\text{diag}(\mathbf{W}^T \mathbf{X} \mathbf{X}^T \mathbf{W}))$, em que $\boldsymbol{\rho} \in \mathbb{R}^{P \times 1}$ e $\text{diag}(\cdot)$ extrai os elementos da diagonal do argumento.

Uma vez que os filtros espaciais correspondentes aos maiores e menores autovalores são os que efetivamente maximizam, de modo recíproco, a variância de uma classe em detrimento de outra, enquanto que autovalores medianos tendem a contribuir menos para a separação, é comum realizar a seleção de $R < P$ filtros para compor um vetor de características de dimensão reduzida, sendo R necessariamente, natural, positivo e par [Blankertz et al. 008a]. A seleção de um número inferior de filtros espaciais equivale a reduzir a complexidade do problema de classificação ao utilizar somente as características mais discriminativas entre classes de IM.

3.5 Classificação dos Sinais de EEG

A partir dos N_T vetores de características do conjunto \mathcal{E}_T juntamente com seus respectivos rótulos \mathbf{t}_T , pode-se treinar um classificador e utilizá-lo para discriminar entre as classes Ω_1 e Ω_2 . Neste trabalho a Análise de Discriminantes Lineares (LDA) é utilizada como algoritmo para classificação dos sinais de EEG. O LDA destaca-se como um dos métodos mais populares para classificação em ICM-IM [Lotte 2014].

O método busca uma projeção ótima $\boldsymbol{\varpi}^*$ para cada vetor de entrada de forma a maximizar a separabilidade inter-classes e minimizar a dispersão intra-classe no espaço de decisão através de seus centroides e de suas matrizes de variância e covariância [Lotte 2014]. Tal projeção maximiza o critério de Fisher, definido como:

$$\arg_{\boldsymbol{\varpi}} \max \frac{\boldsymbol{\varpi}^T \mathbf{S}_\beta \boldsymbol{\varpi}}{\boldsymbol{\varpi}^T \mathbf{S}_\omega \boldsymbol{\varpi}}, \quad (2)$$

onde as matrizes \mathbf{S}_β e \mathbf{S}_ω são, as matrizes de espalhamento inter-classes e intra-classe, respectivamente. A solução ótima para Eq.(2) é dada por

$$\boldsymbol{\varpi}^* = \mathbf{S}_\omega^{-1}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2), \quad (3)$$

em que os vetores $\boldsymbol{\mu}_1$ e $\boldsymbol{\mu}_2$ contêm as médias das classes Ω_1 e Ω_2 ao considerar os vetores de características para cada época no conjunto \mathcal{E}_T . Ao extrair os N_V vetores de características do conjunto \mathcal{E}_V conforme discutido na seção 3.4, a projeção de saída do LDA para o exemplo n é, portanto, dada pela Eq. 4 a seguir:

$$d^{(n)} = \text{sign}(\boldsymbol{\varpi}^T \boldsymbol{\rho}^{(n)}), \quad (4)$$

em que o vetor $\boldsymbol{\rho}^{(n)}$ é o vetor de características correspondente ao exemplo n e $\text{sign}(\cdot)$ extrai apenas o sinal do argumento para compor a classificação final do sinal quanto à tarefa de IM para um dado $\boldsymbol{\rho}^{(n)}$ de forma que $d^{(n)} = 1$ para $\text{sign}(\cdot) \geq 0$ ou $d^{(n)} = 2$ para $\text{sign}(\cdot) < 0$. Ao submeter todas as épocas do conjunto \mathcal{E}_V ao sistema devidamente treinado, obtém-se um vetor \mathbf{d} cujos elementos correspondem às N_V classificações $d^{(n)}$, $\forall n = 1, 2, \dots, N_V$.

3.6 Avaliação de desempenho

A acurácia de classificação foi utilizada como métrica de desempenho associado a cada janela temporal obtida no janelamento. A acurácia é dada pela relação entre o número de classificações corretas e o total de épocas no conjunto \mathcal{E}_V . Ao comparar as classificações em \mathbf{d} com os respectivos rótulos em \mathbf{t}_V , define-se o vetor \mathbf{a} para contabilizar as classificações corretas, em que cada elemento é dado por

$$a^{(n)} = \begin{cases} 1, & \text{se } d^{(n)} = t^{(n)} \\ 0, & \text{se } d^{(n)} \neq t^{(n)} \end{cases}, \forall n = 1, 2, \dots, N_V, \quad (5)$$

Para minimizar as chances de *overfitting* e tornar a avaliação mais robusta utilizou-se validação cruzada 10x5-pastas no conjunto \mathcal{E} por completo. Isso significa que, para cada janela J_i com $i = 1, 2, \dots, K$,

10 iterações são realizadas com as 288 épocas resultantes a fim de se obter acurácias baseadas em múltiplas configurações para os conjuntos \mathcal{E}_T e \mathcal{E}_V . A acurácia em cada iteração da validação cruzada é definida pela relação $\frac{1}{N_V} \sum_{n=1}^{N_V} a^{(n)}$ e o desempenho final de classificação associado à cada janela J_i representa a média entre as iterações, denotada por AM_i .

4. RESULTADOS E DISCUSSÃO

Os resultados obtidos na análise de correlação entre as propriedades da janela e o desempenho médio de classificação são condensados na Figura 3. Primeiramente, o gráfico 3-A apresenta a relação entre a localização e o desempenho do classificador LDA. A predominância de uma correlação fortemente negativa aponta que, para a maioria dos sujeitos, janelas próximas à dica maximizam o desempenho.

O comportamento em 3-A sugere uma reação rápida dos sujeitos para modulação da atividade cerebral assim que a dica é apresentada. Da mesma forma, o afastamento da janela em relação à dica, implica em queda no desempenho médio do modelo de classificação e ilustra uma característica típica de sistemas ICM-IM, amplamente discutida na literatura, que associa baixo desempenho dos sistemas à queda progressiva do engajamento durante a realização do experimento [Clerc et al. 2016].

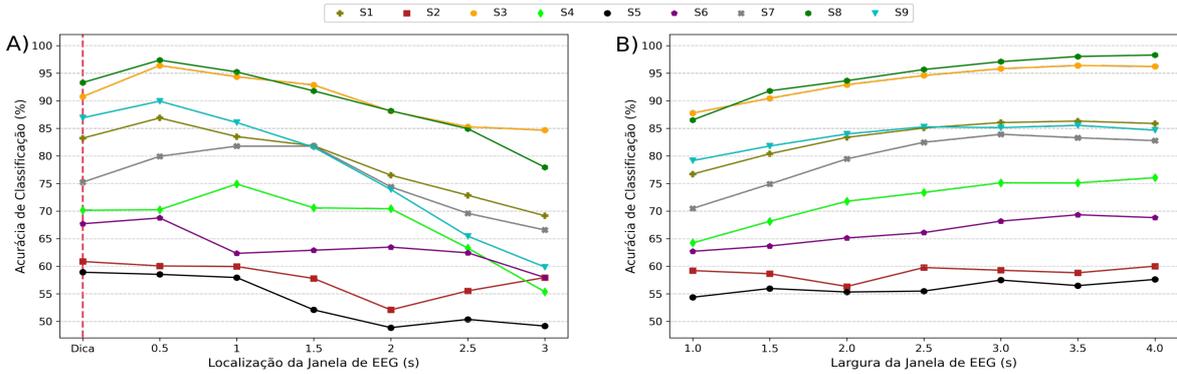


Fig. 3. Variação de desempenho médio de classificação em função de: A) localização D e B) largura L

A Figura 3-B, por sua vez, apresenta a relação entre a largura da janela em segundos e a acurácia de classificação média por largura para os 9 sujeitos, onde é evidenciado que o desempenho de classificação é pouco impactado por janelas com largura igual ou superior a 2 segundos. Por outro lado, janelas menores apresentaram relação instável com o desempenho, isso sugere uma baixa correlação entre a propriedade de largura e a acurácia.

A dispersão entre as janelas ideais, associada à alta variabilidade da atividade cerebral intra e inter-sujeitos e à característica não estacionária do EEG, pode ser observada na Figura 4. Nota-se uma diferença significativa tanto em largura quanto em localização, sugerindo que a extração das épocas de treinamento a partir de janelas personalizadas pode ser uma boa estratégia para maximizar o desempenho de classificação.

5. CONCLUSÕES

A partir dos resultados, nota-se que o desempenho de classificação de sistemas ICM-IM tende a ser influenciado de maneira significativa por ambas as propriedades da janela utilizada para calibrar o sistema. Os resultados apontam que as janelas ideais para os sujeitos avaliados são predominantemente distintas entre si. Observa-se que, em geral, épocas de EEG extraídas de janelas com largura inferior à 1.5 segundos e deslocadas a mais de 1 segundo da dica podem não conter informação suficiente à

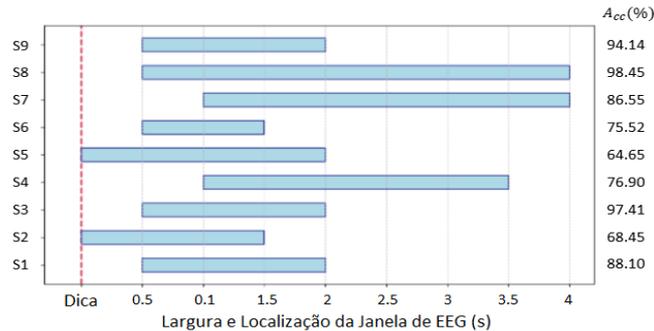


Fig. 4. Janela com melhor desempenho médio de classificação na validação cruzada por sujeito.

ponto de descrever a intenção motora, com janelas maiores e próximas à dica capazes de gerar modelos de classificação com maior capacidade preditiva. Além disso, fica evidente que a definição de janelas cujas propriedades são ajustadas para cada usuário em detrimento à janelas universais independentes do sujeito, mostra-se uma estratégia interessante do ponto de vista de maximização da acurácia de classificação. Por fim, como o estudo neste artigo limitou-se ao problema de classificação binária, apenas para as classes MD e ME, uma análise mais ampla, de modo a considerar outras classes de IM pode ser objeto de estudo futuro uma vez que as características temporais, espaciais e espectrais nos sinais de EEG são notoriamente distintas entre tarefas de IM podendo significar resultados diferentes.

REFERENCES

- BLANKERTZ, B., TOMIOKA, R., LEMM, S., KAWANABE, M., AND MULLER, K. Optimizing spatial filters for robust EEG single-trial analysis. *IEEE Signal Processing Magazine* 25 (1): 41–56, 2008a.
- BRUNNER, C., LEEB, R., MÜLLER-PUTZ, G. R., SCHLÖGL, A., AND PFURTSCHELLER, G. BCI competition 2008 – graz data set a. *Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces)* vol. 16, 2008.
- CLERC, M., BOUGRAIN, L., AND LOTTE, F., editors. *Brain-Computer Interfaces 1*. London, ISTE, 2016.
- FAYYAD, U., PIATETSKY-SHAPIRO, G., AND SMYTH, P. The kdd process for extracting useful knowledge from volumes of data. *Commun. ACM* 39 (11): 27–34, Nov., 1996.
- FENG, J., YIN, E., JIN, J., SAAB, R., DALY, I., WANG, X., HU, D., AND CICHOCKI, A. Towards correlation-based time window selection method for motor imagery BCIs. *Neural Networks* vol. 102, pp. 87–95, 2018.
- GRAIMANN, B., ALLISON, B. Z., AND PFURTSCHELLER, G., editors. *Brain-computer interfaces*. Springer Science & Business Media, 2010.
- LOTTE, F. A tutorial on EEG signal-processing techniques for mental state recognition in brain-computer interfaces. In *Guide to Brain-Computer Music Interfacing*. Number October 2014. Springer, London, pp. 133–161, 2014.
- MINGUILLON, J., LOPEZ-GORDO, M. A., AND PELAYO, F. Trends in EEG-BCI for daily-life. *Biomedical Signal Processing and Control* vol. 31, pp. 407–418, Jan., 2017.
- NEUPER, C. AND PFURTSCHELLER, G. Event-related dynamics of cortical rhythms. *International Journal of Psychophysiology* 43 (1): 41–58, 2001.
- NICOLAS-ALONSO, L. F. AND GOMEZ-GIL, J. Brain computer interfaces, a review. *Sensors* 12 (2): 1211–1279, 2012.
- PFURTSCHELLER, G. AND NEUPER, C. Motor imagery and direct brain-computer communication. *Proceedings of the IEEE* 89 (7): 1123–1134, 2001.
- RAMOSER, H., MULLER-GERKING, J., AND PFURTSCHELLER, G. Optimal spatial filtering of single trial eeg during imagined hand movement. *IEEE Transactions on Rehabilitation Engineering* 8 (4): 441–446, Dez., 2000.
- TEPLAN, M. Fundamentals of EEG measurement. *Measurement science review* 2 (2): 1–11, Jan., 2002.
- URIGÜEN, J. A. AND GARCIA-ZAPIRAIN, B. EEG artifact removal—state-of-the-art and guidelines. *Journal of Neural Engineering* 12 (3): 031001, apr, 2015.
- WOLPAW, J. R., BIRBAUMER, N., MCFARLAND, D. J., PFURTSCHELLER, G., AND VAUGHAN, T. M. Brain-computer interfaces for communication and control. *Clinical neurophysiology* 113 (6): 767–791, Jun., 2002.
- XU, P., LIU, T., ZHANG, R., ZHANG, Y., AND YAO, D. Using particle swarm to select frequency band and time interval for feature extraction of EEG based BCI. *Biomedical Signal Processing and Control* vol. 10, pp. 289–295, 2014.