

DESENVOLVIMENTO DE CLASSIFICADOR PARA TESTE DE INTERFACE DE *FEEDBACK* PARA BCIs: RESULTADOS PRELIMINARES

C.A. Stefano Filho*, T.B.S. Costa**, D.C. Soriano***, R. Attux**, G. Castellano*

*Grupo de Neurofísica, IFGW, UNICAMP, Campinas, Brasil

**Departamento de Computação e Automação, FEEC, UNICAMP, Campinas, Brasil

***Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas, UFABC, Santo André, Brasil
e-mail: carlos.stefanofilho@gmail.com

Resumo: A utilização de interfaces de *feedback* para sistemas de interface cérebro-máquina (BCIs) baseados em imaginação de movimento (MI) pode melhorar a performance de novos usuários. O objetivo deste trabalho foi desenvolver um classificador para ser acoplado a (e assim poder testar) uma interface de *feedback* desenvolvida previamente para um BCI baseado em MI. Três algoritmos classificadores foram implementados: o *k-means* e outros dois métodos alternativos (Métodos A e B), baseados nos máximos e mínimos dos vetores de características. Como este é um estudo preliminar, os vetores de características foram extraídos da transformada de Fourier (FT) de dados de eletroencefalografia (EEG) obtidos do movimento das mãos direita (MD) e esquerda (ME), na faixa de 10 a 18 Hz. Para o *k-means* e o Método A, utilizaram-se os dados adquiridos de três voluntários saudáveis, obtendo-se índices de acerto de 67% e 63%, respectivamente. Ao adicionar um novo voluntário ao conjunto de dados, os dois métodos tiveram seu desempenho reduzido (acerto de 56% para o primeiro e 59% para o segundo), pelo que, utilizou-se o Método B, obtendo um índice de acerto de 84%. No futuro, pretende-se testar os algoritmos com dados de imaginação de movimento. Ainda está se trabalhando no acoplamento do algoritmo à interface de *feedback*.

Palavras-chave: BCI, interface de *feedback*, algoritmo classificador.

Abstract: *The use of feedback interfaces in brain-computer interface systems (BCIs) based in motor imagery (MI) can improve the performance of new users. The goal of this work was to develop a classifier to be coupled to (and thus to test) a feedback interface previously developed for a BCI based on MI. Three classifying algorithms were implemented: k-means and two alternative methods (Methods A and B), based in the maxima and minima of the feature vectors. Since this is a preliminary study, feature vectors were extracted from the Fourier transform (FT) of electroencephalography (EEG) data from movement of the right (MD) and left (ME) hand, in the range 10 to 18 Hz. For k-means and Method A, data from three healthy volunteers were used, obtaining correct classification rates of 67% and 63%, respectively. When a new subject*

was added to the dataset, both methods had their hit rate decreased (56% for the first one and 59% for the second one); therefore, Method B was used, achieving a classification rate of 84%. In the future, we intend to test the algorithms with motor imagery data. We are still working on coupling the classifier to the feedback interface.

Keywords: *BCI, feedback interface, classifying algorithm.*

Introdução

Sistemas de interfaces cérebro-computador, também conhecidos como sistemas BCI (da sigla em inglês, *brain-computer interface*), são aqueles capazes de adquirir sinais cerebrais do usuário como entrada de dados, processá-los e classificá-los segundo determinada intenção deste usuário a fim de controlar um dispositivo externo. Em particular, BCIs baseados em imaginação de movimento (MI, de *motor imagery*) têm sido bastante estudados [1, 2, 3]. Trabalhos recentes têm mostrado que a imaginação de movimento ativa, no cérebro, áreas similares àquelas ativadas pela realização do movimento em si. Por exemplo: imaginar o movimento de uma das mãos gera respostas em áreas motoras do cérebro. Resumidamente, pode-se dizer que a imaginação de movimento pode modificar os ritmos sensoriais e motores dos potenciais cerebrais de uma maneira similar àquela observada na fase de preparação do mesmo movimento [4].

Por outro lado, a utilização de interfaces de *feedback* em BCIs baseados em MI tem se mostrado bastante influente, principalmente para novos usuários, impactando direta e indiretamente sobre suas performances [5, 6]. Em trabalho anterior de nosso grupo, foi desenvolvida uma interface de *feedback* para acoplar a um sistema BCI baseado em MI [7]. Este sistema ainda está em fase de desenvolvimento, sendo que o classificador ainda não está pronto.

O objetivo principal deste trabalho foi, portanto, o desenvolvimento de um algoritmo classificador para ser acoplado à interface de *feedback* desenvolvida, de forma a poder testá-la. As análises dos dados, contudo, estão sendo conduzidas com dados do movimento em si, pois

estes são mais facilmente classificáveis que os dados de imaginação.

Materiais e métodos

Voluntários – Participaram deste trabalho quatro voluntários, consistindo de dois homens e duas mulheres, todos indivíduos saudáveis. Todos os voluntários assinaram um termo de consentimento livre e esclarecido, e o trabalho foi aprovado pelo Comitê de Ética da UNICAMP (número C.A.A.E. 24894313.0.0000.5404).

Aquisição dos dados – O paradigma de aquisição foi realizado em blocos de 10 s cada, alternando blocos de repouso com blocos de movimento da mão direita (MD) e da mão esquerda (ME), por 170 s de aquisição, totalizando 17 blocos, sendo 9 blocos de repouso, 4 de MD e 4 de ME (Figura 1). O movimento realizado consistiu em abrir e fechar a mão (direita ou esquerda), com o voluntário olhando para um monitor de computador que mostrava um cronômetro, e permanecendo com o resto do corpo o mais imóvel possível. Foi pedido para que o voluntário tentasse realizar os movimentos das mãos na mesma frequência em que acompanhava a contagem do cronômetro (o que deveria resultar em uma frequência de 1 Hz para o movimento, ou seja, a mão deveria ser aberta e fechada em 1 s). Cada voluntário realizou este protocolo duas vezes.

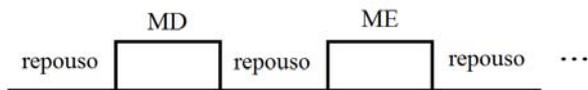


Figura 1 - Esquema dos blocos utilizados no paradigma de aquisição dos dados.

Os dados foram obtidos através de eletroencefalografia (EEG) no sistema usual 10-20 (Figura 2). Na montagem experimental, utilizaram-se 8 eletrodos: C1, C2, C3, C4, C5, C6, FP1, FP2; e mais duas referências localizadas abaixo das orelhas.

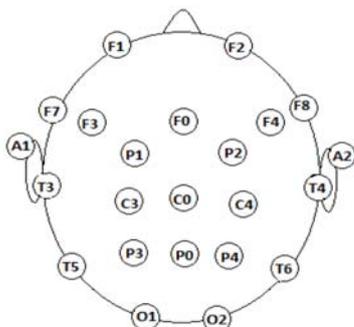


Figura 2 - Montagem do "Sistema 10-20". Números pares são postos à direita e ímpares à esquerda. As letras correspondem aos lobos: F (frontal), T (temporal), P (parietal) e O (occipital), e C corresponde à região central.

Os sinais de EEG foram obtidos com uma taxa de

amostragem de 256 Hz, totalizando 2560 amostras por bloco.

Pré-processamento dos dados – Todas as operações foram realizadas utilizando-se o software MATLAB. Inicialmente, foi feita a transformada de Fourier (FT) para o sinal de cada eletrodo, bloco a bloco. A ideia foi separar os dados em MD e ME. Para isso, para cada FT de cada bloco MD ou ME, tomaram-se os máximos dos valores desses dados no intervalo de 10 a 18 Hz, para cada 2 Hz. Dado que havia oito canais de EEG, isso resultou em 32 amostras por vetor de características.

Classificação dos dados – Foram utilizados três algoritmos classificadores para os dados coletados. O primeiro foi o conhecido algoritmo *k-means clustering* [8] para reconhecimento de padrões, e os outros foram métodos alternativos (Métodos A e B), baseados nos máximos e mínimos dos vetores de características. Os resultados obtidos com o *k-means* e com o Método A foram bastante parecidos, tendo ambos apresentado um decréscimo na taxa de acerto quando se passou da situação de três para quatro voluntários. Isto e o objetivo de melhorar do índice de acerto levaram ao desenvolvimento do Método B que, de fato, obteve melhores resultados que os outros dois métodos nas duas situações.

A seguir são descritos os três métodos. Vale notar que, em todos os casos, uma das aquisições de cada voluntário (4 blocos ME e 4 blocos MD) foi utilizada para treinamento do classificador, e outra para teste. Além disso, todos os vetores foram normalizados pelo valor máximo de cada conjunto de características (ME e MD).

K-means – Este método consiste em calcular os centros de massa (CMs) de cada classe, usando:

$$CM_{ij} = \frac{1}{N} \sum_{k=1}^N c_{ijk}, \quad (1)$$

$$CM_i = (CM_{i1}, CM_{i2}, \dots, CM_{ij}), \quad (2)$$

em que c_{ijk} é a j -ésima coordenada ($j = 1, \dots, J$) da k -ésima amostra ($k = 1, \dots, N$) do vetor de testes da classe i ($i = MD, ME$), CM_i é o vetor centro de massa da classe i com coordenadas CM_{ij} , J é o número de atributos dos vetores de características (neste caso, $J = 32$), e N é o número de amostras para cada classe (dado pelo número de voluntários vezes o número de blocos MD ou ME usados para treino; neste caso, $N = 3 \times 4 = 12$).

Em seguida, calcula-se a distância euclidiana de cada vetor de teste até cada classe, usando:

$$d_i = \sqrt{(CM_{ij} - c_{ij})^2}, \quad (3)$$

em que c_{ij} é a j -ésima coordenada ($j = 1, \dots, J$) de um dado vetor de testes da classe i . O vetor de teste é classificado como pertencente à classe da qual está mais próximo (menor d_i).

Método A – Com os vetores normalizados, calcula-se o CM de cada conjunto (MD e ME), utilizando apenas os vetores de treinamento, como se faria no *k-means*. Em seguida, cada amostra de cada um dos vetores de teste é alocada como pertencendo a um dos três intervalos definidos pelos valores mínimos e máximos dos vetores do CM (Figura 3). Na Figura 3, mín(d), máx(d), mín(e) e máx(e) representam os valores mínimo e máximo dos vetores do CM dos dados MD e ME, respectivamente.

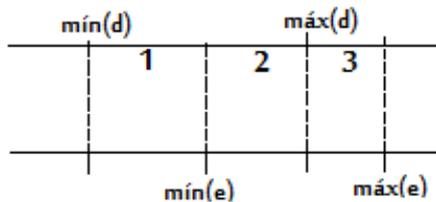


Figura 3 - Ilustração dos intervalos utilizados nos métodos alternativos.

Foram utilizados dois contadores, *dir* e *esq*, ambos inicializados em zero, para cada um dos vetores de teste. Para cada elemento de cada vetor pertencente à região 1 (da Figura 3) foi incrementado o contador da direita (*dir*), para a região 3 (da Figura 3) foi incrementado o da esquerda (*esq*) e, para a região 2, ambos os contadores *dir* e *esq* foram incrementados. Matematicamente, tem-se que:

$$dir = \sum_{j=1}^J x_j; \quad x_j = \begin{cases} 1 & \text{se } v_j < \text{máx}(d); \\ 0 & \text{caso contrário.} \end{cases} \quad (4)$$

$$esq = \sum_{j=1}^J y_j; \quad y_j = \begin{cases} 1 & \text{se } v_j > \text{mín}(e); \\ 0 & \text{caso contrário.} \end{cases} \quad (5)$$

em que $J = 32$ é o número de atributos dos vetores de características (já definido anteriormente para o algoritmo *k-means*), e x_j e y_j podem assumir os valores 0 e 1, segundo o intervalo a que pertence o elemento v_j de cada vetor de teste analisado.

Após a alocação de todos os 32 elementos do vetor de teste nos respectivos intervalos, comparam-se os valores dos dois contadores, e o maior deles indica a classe do vetor (ou seja, se $dir > esq$, o vetor pertence à classe MD, e vice-versa, se $esq > dir$, ele pertence à classe ME).

Método B – Foi realizada a mesma normalização feita nos métodos anteriores, e também foram utilizados os contadores *dir* e *esq*, como no Método A. A principal diferença deste método com o Método A é que, ao invés de analisar os mínimos e máximos dos vetores dos CMs, é feita a análise dos mínimos e máximos globais dos conjuntos de dados de treinamento. Como para cada uma das situações analisadas o mínimo do conjunto ME (mín(e)) foi maior do que o do conjunto MD (mín(d)), cada vez que um elemento do vetor de teste fosse menor do que mín(e), incrementou-se o contador da direita, e caso fosse maior que mín(e), incrementou-se o contador da esquerda. Ou seja, a Eq. 4 foi substituída pela Eq. 6,

enquanto a Eq. 5 continuou válida (sendo que agora mín(e) se refere ao mínimo global, e não mais ao do CM):

$$dir = \sum_{j=1}^J x_j; \quad x_j = \begin{cases} 1 & \text{se } v_j < \text{mín}(e); \\ 0 & \text{caso contrário.} \end{cases} \quad (6)$$

Para o caso em que o valor do contador da direita continuava nulo após este processo, todos os vetores foram renormalizados, agora, pelos valores mínimos de cada conjunto de dados ME e MD. A análise que se seguiu levou em conta, então, os valores máximos de cada um desses conjuntos de dados, e não mais os mínimos. Ou seja, cada vez que um elemento do vetor de teste se apresentou maior que máx(e), incrementou-se uma unidade ao contador da direita, caso contrário, incrementou-se o contador da esquerda (Eqs. 7 e 8, em que máx(e) representa o máximo global do conjunto de dados ME, após renormalização pelo valor mínimo deste conjunto):

$$dir = \sum_{j=1}^J x_j; \quad x_j = \begin{cases} 1 & \text{se } v_j > \text{máx}(e); \\ 0 & \text{caso contrário.} \end{cases} \quad (7)$$

$$esq = \sum_{j=1}^J y_j; \quad y_j = \begin{cases} 1 & \text{se } v_j < \text{máx}(e); \\ 0 & \text{caso contrário.} \end{cases} \quad (8)$$

Como no Método A, a classe do vetor de testes é atribuída de acordo com o contador que possui o maior valor. Na situação em que os valores dos contadores referentes às duas classes são iguais, está se trabalhando em alternativas para adicionar ao método, como comparar as distâncias de cada vetor analisado aos vetores do CM desses conjuntos. Como ainda não se obteve muito sucesso na distinção do conjunto ao qual o vetor de dados pertence para este caso, quando os dois contadores resultaram no mesmo valor, o resultado de classificação foi considerado incorreto.

Resultados

A Tabela 1 mostra as taxas de acerto obtidas com os três métodos de classificação implementados.

Tabela 1: Comparação entre os índices de acerto obtidos pelos três métodos.

Método	% de acerto com 3 indivíduos	% de acerto com 4 indivíduos
<i>k-means</i>	66,65	56,25
Método A	62,50	59,38
Método B	79,17	84,38

O Método A desenvolvido aqui apresentou uma taxa de acerto comparável à do popular algoritmo *k-means clustering*, tendo sido a taxa do Método A um pouco menor para três voluntários (63% contra 67% para o *k-means*) e um pouco maior para quatro voluntários (59% contra 56% para o *k-means*). Ainda assim, ambos os métodos tiveram suas taxas reduzidas quando se aumentou o número de voluntários.

Já para o Método B, também desenvolvido aqui, obteve-se um índice de acerto de 79% com três indivíduos, e, com os quatro indivíduos, esse índice subiu para 84%.

Discussão

Segundo a análise da Tabela 1, percebe-se que as performances do *k-means* e do Método A foram bastante parecidas, sendo que ambos apresentaram um resultado um pouco pior quando se passou de três para quatro indivíduos. Contudo, o Método A apresentou menor variação do índice de acerto, quando comparado ao *k-means*. Além disso, ambos os métodos mostraram-se menos eficientes que o Método B para ambos os conjuntos de três e quatro indivíduos. O Método B apresentou uma taxa de acerto de 79% contra 63% do Método A e 67% do *k-means* para o primeiro caso, e de 84% contra 59% do Método A e 56% do *k-means* para o segundo caso. Para ambos os métodos alternativos, quando os contadores dos conjuntos de dados de MD e ME resultaram no mesmo valor, o resultado de classificação foi considerado incorreto, assim, sua eficácia ainda pode ser melhorada pensando-se em estratégias para classificar os dados neste tipo de situação.

É válido ressaltar que todas as análises foram realizadas com movimento e, futuramente, espera-se que esses índices se mantenham e ainda possam ser melhorados quando os algoritmos forem acoplados à interface de *feedback* para o sistema BCI baseado em MI. A grande variabilidade inter-indivíduo existente constitui, ainda, grande obstáculo no desenvolvimento de um classificador preciso. Durante este trabalho, ficou claro que nem sempre o mesmo classificador funciona igualmente bem para indivíduos diferentes. Portanto, estudos futuros ainda são requeridos para aprofundamento do conhecimento nos métodos de classificação já existentes e aprimoramento daqueles já desenvolvidos para o caso deste estudo, a fim de se diminuir as dificuldades encontradas. Espera-se que os índices de acerto possam ser melhorados combinando-se ajustes aos métodos já desenvolvidos com novos métodos e com aquisições de sinais cerebrais de diferentes indivíduos.

Agradecimentos

Agradecemos à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelo apoio financeiro.

Referências

- [1] Cincotti F, Mattia D, Babiloni C, Carducci F, Salinari S, Bianchi L, Marciani MG, Babiloni F. The use of EEG modifications due to motor imagery for brain-computer interfaces. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. 2003; 11(2): 131 - 133.
- [2] Neuper C, Scherer R, Reiner M, Pfurtscheller G. Imagery of motor actions: Differential effects of kinesthetic and visual-motor mode of imagery in single-trial EEG. *Cognitive Brain Research*. 2005; 25: 668 - 677.
- [3] Pfurtscheller G, Neuper C. Motor imagery and direct brain-computer communication. *Proceedings of the IEEE*. 2001; 89(7): 1123 - 1134.
- [4] Pfurtscheller G, Neuper C, Birbaumer N. Human Brain-Computer Interface. Em: Vaadia E, Riehle A. *Motor cortex in voluntary movements: a distributed system for distributed functions*. CRC Press. 2005. p. 405 - 440.
- [5] McFarland DJ, McCane LM, Wolpaw JR. EEG-based communication and control: short-term role of feedback. *IEEE Transactions on Rehabilitation Engineering*. 1998; 6(1): 7 - 11.
- [6] Hwang HJ, Kwon K, Im CH. Neurofeedback-based motor imagery training for brain-computer interface (BCI). *Journal of Neuroscience Methods*. 2009; 179: 150 - 156.
- [7] Stefano Filho CA, Costa TBS, Soriano D, Attux R, Castellano G. Development of a feedback interface for motor imaging based brain-computer interfaces: preliminary results. *Journal of Epilepsy and Clinical Neurophysiology*. 2014; 20(Suppl 2): 26 - 27.
- [8] Duda RO, Hart PE, Stork DG. *Unsupervised learning and clustering*. Em: *Pattern Classification*. 2ª ed. 2001. p. 517 - 600.