

BCI baseado em imagética motora explorando representações esparsas dos sinais

V. Ormenesse*, R. Suyama*

*CECS, UFABC, Santo André, Brasil

e-mail: vinicius.ormenese@aluno.ufabc.edu.br, ricardo.suyama@ufabc.edu.br

Abstract - *Brain-computer interfaces are intended to process and translate brain signals into commands which computers are capable to understand. In this work, the EEG signal classification in a motor imagery BCI system is performed using dictionary learning and sparse signals representation. The results indicate that sparse representation of the EEG signals is able to increase the classification performance of the system.*

Palavras-chave: *brain-computer interface, electroencephalogram, classification, Sparse Encoding, Dictionary Learning.*

Introdução

O BCI (do inglês, Brain Computer Interface em português, interface cérebro-máquina) oferece uma alternativa para comunicação e controle de dispositivos, captando os sinais diretamente no escalpo do indivíduo e efetuando o devido processamento para identificação da intenção e/ou comando do usuário [1]. Os sistemas, em geral, buscam explorar a informação contida em todos os sinais de eletroencefalografia (EEG) coletados. Processar corretamente estes sinais ainda é uma tarefa complexa e pouco assertiva, principalmente em sistemas não invasivos de EEG. Desta maneira, esse trabalho explora-se a utilização de ferramentas para representação esparsa dos sinais para auxiliar no processo de classificação dos mesmos.

De fato, a esparsidade já foi explorada no contexto de BCI baseado em imagética motora [2–4]. No presente artigo, entretanto, utiliza-se uma abordagem semelhante à exposta em [5], na qual os vetores esparsos são criados a partir de um dicionário que represente a densidade espectral dos sinais de EEG de interesse, retratando-a da maneira mais esparsa possível, auxiliando assim, na classificação dos sinais em melhorando o desempenho geral do BCI.

Representação Esparsa

O conceito de esparsidade nos remete a sinais que possuem uma grande quantidade regiões com va-

lores nulos ou quase nulos em algum domínio, ou seja, sinais em que toda informação está concentrada em uma quantidade pequena de valores que representam aquilo que se analisa [6]. Uma maneira de se quantificar o grau de esparsidade é determinar quantas amostras ou quantos coeficientes do sinal possuem valores não-nulos, noção que está relacionada à norma ℓ_0 do vetor. Como em sinais reais dificilmente observam-se coeficientes exatamente nulos, é possível definir um limiar a partir do qual o coeficiente é considerado nulo, levando à definição de outras normas, como a norma $\ell_{0\epsilon}$.

Encontrar uma representação esparsa para um determinado vetor (sinal) \mathbf{y} pressupõe a existência de um dicionário representado por uma matriz \mathbf{D} , e consiste em encontrar um vetor \mathbf{x} esparso tal que $\mathbf{y} = \mathbf{D}\mathbf{x}$. Matematicamente, o sinal pode ser representado por vetor esparso que é definido pelo seguinte problema de otimização

$$\min_x \|\mathbf{x}\|_0 \quad \text{sujeito a} \quad \mathbf{y} = \mathbf{D}\mathbf{x} \quad (1)$$

Ou ainda,

$$\min_x \|\mathbf{x}\|_0 \quad \text{sujeito a} \quad \|\mathbf{y} - \mathbf{D}\mathbf{x}\|_2 \leq \epsilon \quad (2)$$

para um limiar ϵ pequeno.

Em geral, não é possível garantir a solução global do problema descrito acima, e diferentes algoritmos foram propostos na literatura para a obtenção da representação esparsa (também conhecida como codificação esparsa), dentre as quais pode-se destacar o *Basis Pursuit* (BP) e *Orthogonal Matching Pursuit* (OMP), e o algoritmo LARS (do inglês, Least-Angle Regression) [6].

Aprendizado de Dicionário

O grau de esparsidade da representação de um sinal está diretamente relacionada ao dicionário utilizado. Em muitas aplicações, por exemplo, as colunas da matriz \mathbf{D} representam funções bases de transformadas lineares bastante conhecidas, como a transformada discreta de Fourier e a transformada do Cosseno discreto. Entretanto, é possível obter uma representação com um maior grau de esparsidade obtendo-se um dicionário específico

para o tipo de sinal processado. Para isso, diferentes algoritmos de aprendizado de dicionário foram propostos na literatura [7], que, em geral, são baseados em uma estratégia de dois estágios, conforme ilustrado na Figura 1 e descrito a seguir:

1. Inicialização: Um dicionário \mathbf{D} é criado aleatoriamente;
2. Codificação Esparsa: Obtém-se a representação esparsa \mathbf{X} dos dados, considerando a matriz de dicionário \mathbf{D} , de acordo com o problema de minimização apresentado em (1);
3. Atualização do Dicionário: Com base na representação esparsa encontrada, atualizar \mathbf{D} de maneira a minimizar $\|Y - DX\|_F^2$;
4. Enquanto não convergir, volte ao passo 2;

Alguns dos métodos propostos na literatura e que seguem a abordagem descrita anteriormente são o K-SVD [6], o RLSDLA (*recursive least square dictionary learning algorithm*) e LSDLA (*least square dictionary learning algorithm*) [7], e o ODL (*online dictionary learning*) [8] e MOD (*Method of Optimal Directions*) [9].

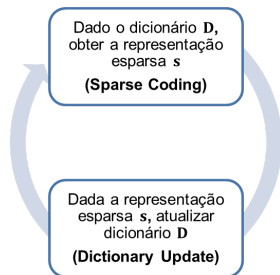


Figura 1 – Diagrama ilustrando o processo iterativo de criação de dicionário a partir de um dicionário inicial \mathbf{D}_0 .

BCI baseado em Imagética Motora

O sistema BCI baseado em imagética motora busca classificar os sinais coletados quando os voluntários imaginam algum movimento específico, como chutar uma bola ou fechar a mão esquerda. No presente trabalho, a fim de avaliar a metodologia de classificação baseada em representação esparsa, foram utilizadas as bases de dados disponibilizadas em uma competição internacional, denominada “BCI Competition IV” [10], organizada por pesquisadores envolvidos com o tema. As bases de dados são fornecidas no formato “. mat” do Matlab, e o conjunto de dados do EEG utilizado

consiste em gravações de 9 indivíduos diferentes. As gravações estão relacionadas a 4 tarefas motoras que foram imaginadas pelos indivíduos: Movimentação da mão esquerda; Movimentação da mão direita; Movimentação de ambos os pés; e Movimentação da língua.

Para a captura dos dados, os indivíduos ficavam confortavelmente sentados em uma tela de computador. No começo da gravação ($t = 0s$), uma cruz aparece na tela indicando o início da gravação, e após dois segundos ($t = 2s$), uma flecha apontando para alguma direção; direita, esquerda, baixo ou cima (correspondendo as 4 classes a serem treinadas, mão direita e esquerda, pés e língua) surge na tela e permanece ativa por $t = 1.25s$. A gravação é realizada por 4 segundos a partir da aparição da flecha na tela. Na gravação de EEG são utilizados 22 eletrodos, e os sinais amostrados a uma frequência de 250 Hz (passado por um filtro passa banda entre as frequências de 0,5 Hz e 100 Hz).

Classificação baseada em Representação Esparsa

Para a classificação dos sinais neurais multi-classe provenientes de EEG, foram utilizadas duas abordagens distintas. O primeiro método estudado, que se refere à abordagem clássica para classificação dos sinais, baseia a decisão sobre qual movimento o usuário está imaginando diretamente na densidade espectral de potência dos sinais coletados. No segundo método, a classificação é feita sobre uma representação esparsa da densidade espectral de potência. Ambos procedimentos são apresentados nas figuras 2 e 3. Em ambas abordagens adotou-se uma classificação utilizando o algoritmo k-NN (*k-nearest neighbors*) [11].

Para fins de avaliação das duas abordagens, os conjunto de dados foi separado aleatoriamente em dois grupos, sendo o primeiro deles, composto por 70% das amostras, para treinamento do classificador, e o segundo grupo, composto das 30% amostras restantes, para validação.

O filtro para pré-processamento dos dados consistiu de um filtro passa-banda FIR, projetado com janelas de Kaiser e ordem 20, com frequências entre 0,5 Hz e 20 Hz. Após a utilização do filtro, utiliza-se o método CSP (*Common Spatial Pattern*) multi-classe para tentar maximizar a diferença na densidade espectral de potência nas diferentes classes de dados [12].

Para a criação do dicionário a ser utilizado na representação esparsa das densidades espectrais,

foram utilizadas as técnicas de criação mencionadas anteriormente (K-SVD, ODL, MOD, ILSDLA, RLSDLA). Com base nos dicionários obtidos, são extraídas as representações esparsas das densidades espectrais de potência, passo que deve, teoricamente, melhorar o desempenho na classificação.

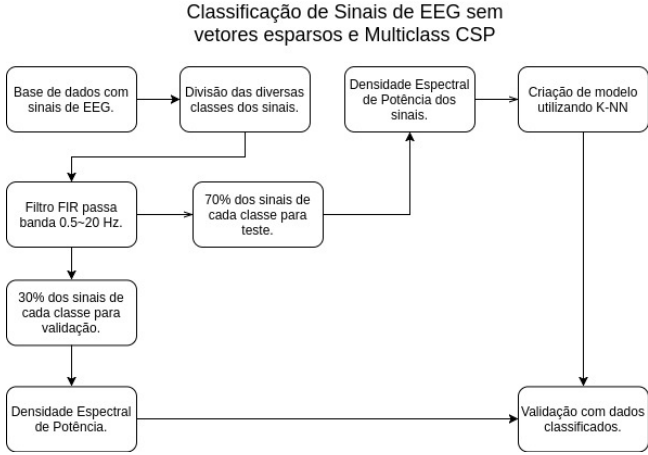


Figura 2 – Método utilizado para classificação de sinais de EEG sem a utilização de vetores esparsos.

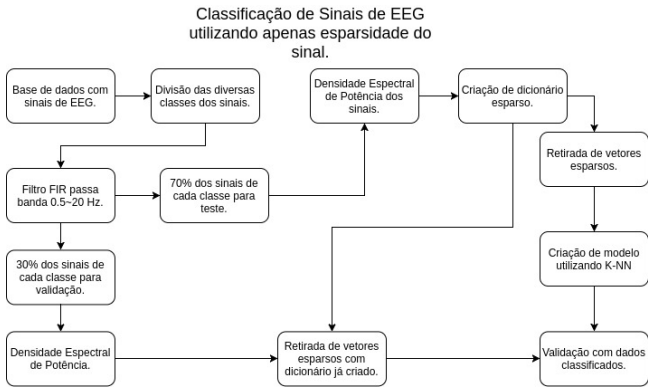


Figura 3 – Método utilizado para classificação de sinais de EEG com a utilização de vetores esparsos.

Resultados

Os resultados obtidos com as duas abordagens são compilados nas Tabelas 1 e 2. A performance do método é quantificada em termos do coeficiente $Kappa$, bastante utilizado na comparação de desempenho entre sistemas BCI, e definido por

$$\kappa = \frac{p_0 - p_e}{1 - p_e} \quad (3)$$

onde p_0 representa o percentual de classificações corretas, e p_e a probabilidade do acerto na classificação ter sido ao acaso. Um valor $\kappa = 1$ indica a situação de classificação perfeita, e $\kappa = -1$ a

Tabela 1 – Comparação de resultados obtidos com o método sem considerar a esparsidade (método 1).

Ind.	Acurácia Kappa	
	1º colocado [10]	Método 1
-		
1	0.68	0.41 ± 0.03
2	0.42	0.35 ± 0.03
3	0.75	0.32 ± 0.03
4	0.48	0.37 ± 0.03
5	0.40	0.38 ± 0.03
6	0.27	0.36 ± 0.03
7	0.77	0.34 ± 0.03
8	0.75	0.34 ± 0.03
9	0.61	0.33 ± 0.03
Média	0.57	0.36 ± 0.03

situação na qual todas as classificações foram incorretas.

Para o método 1, utiliza-se o sinal após a pré-filtragem e estima-se a densidade espectral de potência do sinal (DEP). Com isso, com o sinal amostrado em 250 Hz, obtém-se um vetor de 257 elementos, dos quais apenas os primeiros 50 elementos do vetor são considerados (os demais apresentam valores praticamente nulos), utilizado no processo de classificação. O método 2 utiliza os métodos de criação de dicionário esparsos onde utiliza-se o sinal após a pré-filtragem e estima-se a DEP como no método 1. Com os vetores de treinamento (70% das amostras ou 5040 vetores) é criado um dicionário de tamanho 50×5040 e inicializa-se este dicionário com os próprios vetores. Para obtenção da representação esparsa do sinal, neste trabalho utiliza-se o algoritmo OMP [13].

Tabela 2 – Classificação utilizando o método 2, utilizando esparsidade do sinal.

Resultados - Método 2					
Ind.	Acurácia Kappa ±0.03				
	MOD	RLSDLA	LSDLA	ODL	K-SVD
-					
1	0.79	0.54	0.63	0.82	0.54
2	0.80	0.49	0.56	0.79	0.52
3	0.82	0.48	0.54	0.77	0.50
4	0.80	0.49	0.59	0.76	0.49
5	0.78	0.53	0.58	0.76	0.52
6	0.79	0.52	0.60	0.80	0.54
7	0.80	0.50	0.65	0.83	0.60
8	0.82	0.60	0.66	0.85	0.57
9	0.81	0.65	0.63	0.85	0.49
Média	0.80	0.53	0.60	0.80	0.53

Os resultados obtidos com a abordagem clássica (Tabela 1) são comparados com os valores de κ obtidos na competição BCI *Competition IV* [10]. Observa-se que para a maioria dos indivíduos, o método ficou aquém do desempenho alcançado pelo melhor colocado da competição - apenas para o indivíduo 6 a metodologia apresentou resultado melhor, com desempenho médio global cerca de 20% menor do que o melhor colocado.

Por outro lado, o uso da representação esparsa das densidades espectrais de potência, parece trazer benefícios para a classificação dos sinais. Conforme observado na Tabela 2, para alguns dos métodos analisados, foi possível obter desempenho global médio superiores ao melhor resultado da competição. A diferença de desempenho dos diferentes algoritmos era esperada, uma vez que não se garante unicidade na obtenção dos dicionários.

Conclusões

No presente trabalho é apresentado um estudo comparativo entre duas abordagens para a classificação de sinais de EEG, aplicados a sistemas BCI baseados em imagética motora. A partir dos resultados obtidos, que utilizam uma base de dados disponível gratuitamente, pode-se constatar o benefício em se utilizar a representação esparsa do sinal para classificação do sinal de EEG. Alguns métodos de criação de dicionário como os algoritmos MOD e ODL, proporcionaram vetores esparsos cuja eficácia da classificação foi melhor que o primeiro colocado da competição BCI. Como trabalho futuro, deseja-se investigar formas para a redução de complexidade computacional do sistema estudado, visando a implementação da solução em um sistema de BCI online, ou seja, em tempo real.

Agradecimentos

Os autores agradecem à CAPES e ao CNPq (Proc. 310610/2015-0) pelo apoio financeiro.

Referências

- [1] J. Wolpaw and E. W. Wolpaw, *Brain-Computer Interfaces: Principles and Practice*. Oxford University Press, 2012.
- [2] Y. Shin, S. Lee, M. Ahn, S. C. Jun, and H. N. Lee, “Motor imagery based bci classification via sparse representation of eeg signals,” in *Proc. of NFSI ICBEM 2011*, pp. 93–97, 2011.
- [3] W. Zhou, Y. Yang, and Z. Yu, “Discriminative dictionary learning for eeg signal classification in brain-computer interface,” in *12th Int. Conf. on Control Automation Robotics Vision (ICARCV)*, pp. 1582–1585, 2012.
- [4] D. Wen, P. Jia, Q. Lian, Y. Zhou, and C. Lu, “Review of sparse representation-based classification methods on eeg signal processing for epilepsy detection, brain-computer interface and cognitive impairment,” *Frontiers in Aging Neuroscience*, 2016.
- [5] R. Ameri, A. Pouyan, and V. Abolghasemi, “Projective dictionary pair learning for eeg signal classification in brain computer interface applications,” *Neurocomputing*, vol. 218, no. Supplement C, pp. 382 – 389, 2016.
- [6] M. Elad, *Sparse and Redundant Representations: From Theory to Applications in Signal and Image Processing*. Springer Publishing Company, Incorporated, 1st ed., 2010.
- [7] K. E. Karl Skretting, “Learned dictionaries for sparse image representation: properties and results,” in *Proc.SPIE*, vol. 8138, 2011.
- [8] J. Mairal, F. Bach, J. Ponce, and G. Sapiro, “Online dictionary learning for sparse coding,” in *Proceedings of the 26th Annual International Conference on Machine Learning, ICML '09*, (New York, NY, USA), pp. 689–696, ACM, 2009.
- [9] K. Engan, S. O. Aase, and J. H. Husoy, “Method of optimal directions for frame design,” in *Proc. 1999 IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP99)*, vol. 5, pp. 2443–2446, 1999.
- [10] M. Tangermann and K.-R. Müller et. al., “Review of the bci competition iv,” *Frontiers in Neuroscience*, vol. 6, 2012.
- [11] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification (2Nd Edition)*. Wiley-Interscience, 2000.
- [12] E. Boualem Boashash, *Time Frequency Signal Analysis and Processing: A Comprehensive Reference*. Elsevier Science, 1 ed., 2003.
- [13] M. A. Hameed, “Comparative analysis of orthogonal matching pursuit and least angle regression,” Master’s thesis, Michigan State University, Michigan, EUA, 2012.