

CLASSIFICAÇÃO COM MÁQUINA DE VETORES DE SUPORTE E COERÊNCIA NA IMAGÉTICA MOTORA COM PRÁTICA MENTAL

Erazo-Costa, F.¹, Santos, C.C.², Gomes, M.E.D¹ and Tierra-Criollo, C.J.^{1,2}

¹Programa de Pós-Graduação em Engenharia Elétrica - Universidade Federal de Minas Gerais - Av. Antônio Carlos 6627, 31270-901, Belo Horizonte, MG, Brasil

²Programa de Pós-Graduação em Neurociências - Universidade Federal de Minas Gerais - Av. Antônio Carlos 6627, 31270-901, Belo Horizonte, MG, Brasil

e-mail: fabricio.erazo@gmail.com

Abstract – A brain computer interface (BCI) is a system that communicates a person with an electronic device by means of mental signals. Pattern recognition is an important module for BCIs because it translates brain activity into commands for the activation of a machine. This paper aims at presenting the relation between mental practice and the algorithm classifier support vector machine in combination with the magnitude squared coherence for the classification of motor imagery movements of the index finger (imagination and spontaneous). An accuracy of 98 % was found with one subject with the training of the machine with data for the four sessions and validation of session 5. Furthermore, an incremental accuracy of the classification around the different sessions was found for all subjects with mental practice. This approach could be used for the development of BCIs.

Keywords – Mental Practice, coherence, SVM.

1 Introdução

A interface cérebro máquina (ICM) é um sistema capaz de comunicar um indivíduo e um dispositivo eletrônico mediante o processamento de sinais cerebrais. O principal objetivo é auxiliar pessoas com deficiência por meio do controle de membros artificiais [1].

O reconhecimento de padrões de sinais de eletroencefalografia (EEG) relacionado a tarefas mentais é um módulo muito importante dentro da investigação das ICMs [2]. Para controlar este tipo de interface, os padrões devem ser identificados e convertidos em comandos para acionar uma máquina. Esta identificação é feita pelo uso de algoritmos de classificação. Dentre os classificadores, pode-se citar: classificadores lineares, redes neurais, classificadores bayesianos não lineares, classificadores do vizinho próximo e a combinação de classificadores [3]. Os estudos realizados por Ahmadi et al [4] demonstraram que a utilização de redes neurais probabilísticas recorrentes para classificação de movimentos de preensão da mão direita e esquerda com prática mental incrementou a taxa de acerto da primeira sessão (80%) –processamento off line e sem treinamento- em comparação com a última sessão e utilizando uma única imaginação (73% a 91%). Entretanto, Ming et al [5] utilizaram a Máquina de Vetores de Suporte (SVM) em conjunto com análises de componentes independentes para a classificação de movimentos motores encontrando uma taxa de acerto entre 77,6% e 91,4%.

Um dos fatores mais importantes para a robustez dos classificadores é a extração de características. A técnica estatística magnitude quadrática da coerência (MSC) tem-se mostrado promissora para a detecção de tarefas motoras [6]. Por conseguinte, a MSC é utilizada neste trabalho como entrada para o algoritmo de classificação. O classificador utilizado é a máquina de vetores de suporte (SVM) porque em ICMs obteve-se os melhores resultados em experimentos *síncronos* e é robusto com respeito a altas dimensionalidades [3].

Visando favorecer a identificação de padrões de atividade cerebral relacionada à imaginação motora (IM), este estudo tem como objetivo verificar se a prática mental baseada em IM influencia sobre a taxa de acerto da classificação da imaginação do movimento do dedo indicador.

2 Materiais e métodos

Quatro indivíduos saudáveis, do sexo masculino, na faixa etária de 20-25 anos, com capacidade de imaginar avaliados pelo Questionário de Imaginação Motora –Revisado (MIQ -R) [7], com índice médio de 80 ± 8.02 , sem alteração cognitiva ou comprometimento neurológico, participaram deste estudo.

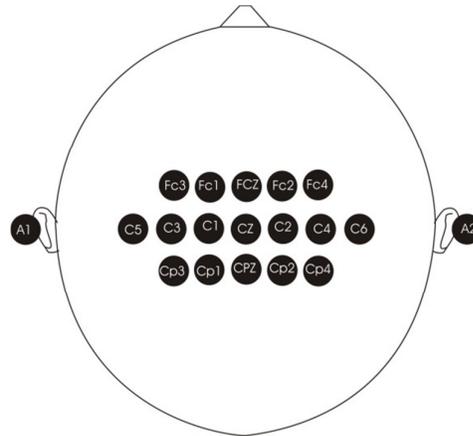


Figura 1 – Sistema de posicionamento de eletrodos 10/10.

Todas as coletas foram realizadas no Laboratório de Engenharia Biomédica da UFMG, de acordo com o protocolo aprovado pelo Comitê de Ética Local. Os sinais do eletroencefalograma (EEG) foram coletados utilizando o bioamplificador BrainNet-36, com um filtro passa-faixa de 0,1 – 100Hz, filtro Notch de 60 Hz e frequência de amostragem de 600 Hz.

Os eletrodos de captação foram posicionados de acordo com o sistema 10/10 (referência), tendo como referência os eletrodos auriculares (A1 e A2). Foram utilizados 17 eletrodos dispostos na área do escalpo relacionada ao córtex sensoriomotor [8], como mostrado na figura 1.

Cinco sessões de prática mental baseada em IM de extensão e flexão do dedo indicador da mão dominante foram realizadas. Cada sessão foi composta por dois momentos: (1) EEG espontâneo e (2) EEG durante a IM, com duração de 10 e 15 minutos, respectivamente. Dois LEDs (Light Emitting Diodes) – um vermelho e outro amarelo - colocados a uma distância de 80 cm dos olhos do indivíduo foram usados como comando para a realização da IM. Quatro segundos antes do indivíduo iniciar a tarefa ($t = -4$ s), o LED vermelho era aceso, orientando-o a ficar atento. Um segundo antes da tarefa ($t = -1$ s), o LED amarelo era aceso para indicar a preparação para a execução da tarefa. O desligamento de ambos os LEDs indicava que o indivíduo deveria executar a tarefa mental ($t = 0$ s). Após 10s de repouso, o processo reiniciava-se (Figura 2), resultando em um trecho (M) de 14s. No total do experimento teve-se aproximadamente $M=64$ e $M=42$ trechos para IM e espontâneo, respectivamente.

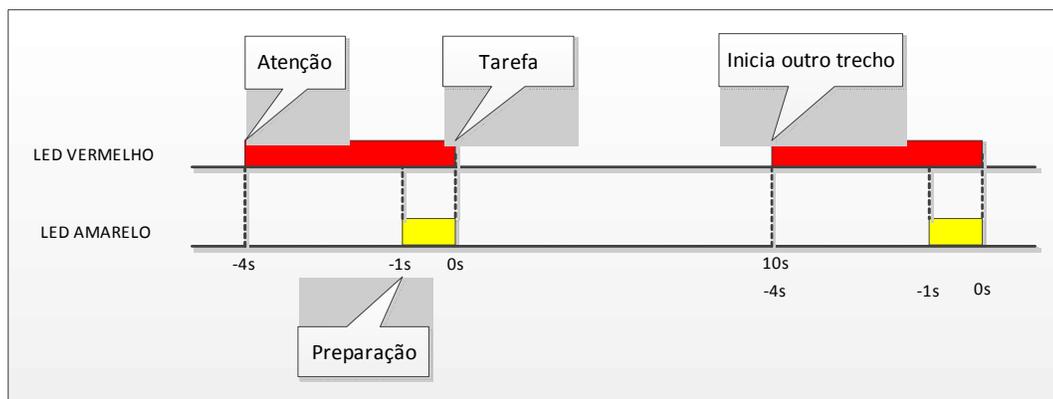


Figura 2 – Protocolo utilizado. Trecho (M) definido entre -4s e 10s.

Os sinais captados pelos 17 eletrodos foram filtradas *off line* com um filtro digital Butterworth de ordem 2 e banda de 0,1 a 30 Hz. Cada sinal foi dividido em trechos sincronizados nos intervalos -0,7 a 2,3 s, uma vez que a resposta cortical da tarefa motora encontra-se neste período de tempo [8]. Os trechos considerados como artefatos foram removidos segundo descrito por [9].

A Magnitude Quadrática de Coerência

A coerência pode ser definida pela seguinte fórmula [10]

$$\gamma_{xy}(f) = \frac{P_{xy}(f)}{\sqrt{P_{yy}(f)}\sqrt{P_{xx}(f)}} \quad (1)$$

Onde $P_{xy}(f)$ é a densidade espectral cruzada de potência (PSD) entre dois sinais e $P_{xx}(f)$ e $P_{yy}(f)$ são as PSDs de cada sinal. A MSC é o quadrado da coerência e tem a seguinte expressão

$$\kappa(f) = |\gamma_{xy}(f)|^2 = \frac{|P_{xy}(f)|^2}{P_{yy}(f)P_{xx}(f)} \quad (2)$$

Para sinais ergódicos com M trechos, a estimativa pode ser dada pela fórmula

$$\hat{\kappa}(f) = \frac{|\sum_{i=1}^M Y_i(f) X_i^*(f)|^2}{\sum_{i=1}^M |Y_i(f)|^2 \sum_{i=1}^M |X_i(f)|^2} \quad (3)$$

Onde * denota o conjugado complexo $Y_i(f)$ e $X_i(f)$ são Transformadas Discretas de Fourier do i-ésimo trecho dos sinais

Considerando-se a tarefa de IM como $y(n)$ e idêntica em todos os trechos do sinal, e $x(n)$ como sinal de EEG no escalpo, tem-se:

$$MSC(f) = \frac{|\sum_{i=1}^M X_i(f)|^2}{M \sum_{i=1}^M |X_i(f)|^2} \quad (4)$$

Para M trechos independentes de sinal gaussiano, a MSC está relacionada com a distribuição β da seguinte forma [11].

$$MSC(f) \sim \beta_{1,(M-1)} \quad (5)$$

Onde $\beta_{1,(M-1)}$ é a distribuição beta com 1 e M-1 graus de liberdade. O valor crítico da MSC para um nível de significância α é dado pela expressão

$$MSC_{crit} = \beta_{crit,\alpha,1,(M-1)} \quad (6)$$

A resposta sincronizada com o evento na frequência f é identificada para $MSC(f) > MSC_{crit}$.

Para a extração de características utilizou-se a MSC, que representa o valor de dependência linear entre os diferentes harmônicos dos estímulos e a resposta nos sinais de EEG.

Foram escolhidos 12 trechos para estimar a MSC entre eles. Cada sinal de cada eletrodo foi normalizado para um número de trechos múltiplo de 12 para obter as observações do vetor de entrada para o SVM. A extração de características foi feita na banda delta na faixa de 0 a 1 Hz.

Para a classificação, foram utilizadas duas classes denominadas: 'Espontâneo' e 'Imaginação'.

Máquina de Vetores de Suporte (SVM)

A SVM tem como ideia principal construir um hiperplano para maximizar a separação entre dados das diferentes classes. Consiste em um mapeamento não linear de um vetor de entradas para um espaço de características de alta dimensionalidade (que, inclusive, poderia ser infinita). [12]

A SVM representa uma minimização estrutural de risco. Este método para padrões separáveis produz um valor de zero para a soma de taxa de erros para o treinamento e minimiza a dimensão de Vapnik-Chervonenkis (V-C). [13]

Para o mapeamento não linear usou-se o kernel gaussiano ou função de bases radiais (RBF), uma vez que gera bons resultados em ICMs[3]. O kernel gaussiano tem a seguinte estrutura:

$$K(\mathbf{x}, \mathbf{x}_i) = \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{x} - \mathbf{x}_i\|^2\right) \quad (6)$$

Onde:

\mathbf{x} é o vetor de entradas

\mathbf{x}_i é padrão de entrada do i -ésimo exemplo

A importância do núcleo do produto interno (kernel) é que serve para construir o hiperplano ótimo no espaço de características sem ter que considerar o próprio espaço de características de forma explícita. Utilizando o kernel pode-se formular o problema dual para otimização dos dados como: [13,14]

Com as amostras de treinamento $\{(\mathbf{x}_i, d_i)\}_{i=1}^N$ encontre os multiplicadores de Lagrange $\{\alpha_i\}_{i=1}^N$ que maximizam a função objetivo:

$$Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j d_i d_j K(\mathbf{x}_i, \mathbf{x}_j) \quad (7)$$

Sujeitos às restrições:

- 1) $\sum_{i=1}^N \alpha_i d_i = 0$
- 2) $0 \leq \alpha_i \leq C$ para $i=1,2,\dots,N$

Onde C é um parâmetro positivo definido pelo usuário, d_i é a resposta desejada na saída.

Uma vez encontrados os valores ótimos dos multiplicadores de Lagrange, representados por $\alpha_{0,i}$, pode-se obter o valor ótimo correspondente do vetor linear de peso \mathbf{w}_0 , que conecta o espaço de características ao espaço de saída, que cumpre com o problema primordial de otimização para a minimização da função custo $\Phi(\mathbf{w}) = \frac{1}{2} \mathbf{w}^T \mathbf{w}$ e que satisfaça a restrição $d_i(\mathbf{w}^T \varphi(\mathbf{x}_i) + b) \geq 1$. O valor ótimo de \mathbf{w}_0 tem a seguinte forma:

$$\mathbf{w}_0 = \sum_{i=1}^N \alpha_{0,i} d_i \varphi(\mathbf{x}_i) \quad (8)$$

Onde $\varphi(\mathbf{x}_i)$ é a imagem induzida no espaço de características devido a \mathbf{x}_i . A primeira componente de \mathbf{W}_0 representa o bias ótimo b_0 .

3 Resultados

Foram obtidas a MSC com os 12 primeiros trechos de cada eletrodo. A figura 3 exemplifica a MSC nos eletrodos FC1 (frontal-central ipsilateral), Cz (central) e CP2 (central-parietal contralateral) do sujeito s1 na sessão 5. As linhas de maior e de menor espessuras representam a MSC da IM e do espontâneo, respectivamente. A linha horizontal paralela ao eixo X indica o limiar de detecção. Os resultados mostram que a MSC dos diferentes trechos dos eletrodos conseguem uma detecção na banda delta (0-4Hz) quando se trata de IM e não tem detecção para o espontâneo. O principal padrão de resposta para a tarefa motora encontra-se na banda delta inferior, aproximadamente de 0 a 1 Hz.

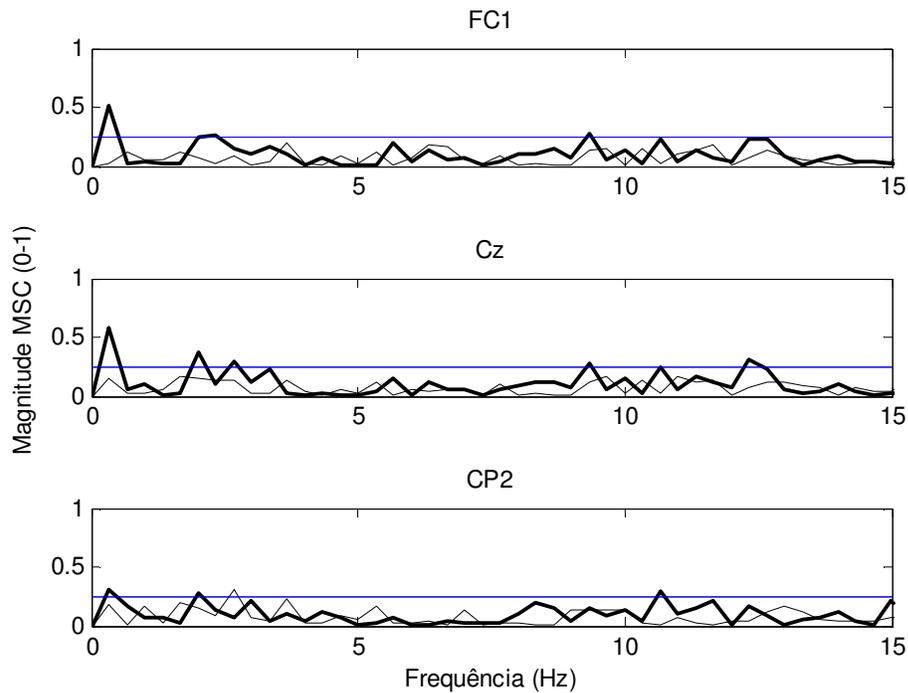


Figura 3 – Valores da MSC para IM nos eletrodos FC1, Cz e CP2 do voluntário s1 da sessão 5. Linha grossa corresponde à MSC da IM e a linha fina ao EEG espontâneo. A linha horizontal indica o limiar de detecção MSCcrit

A tabela 1 mostra a taxa de acerto do classificador SVM para cada sujeito após o treinamento com as quatro primeiras sessões e validação com a quinta sessão de cada indivíduo. A característica foi a MSC da banda de 0 a 1Hz. Nos sujeitos s1, s2, s3 e s4 obteve-se uma taxa de acerto de 0.95, 0.7, 0.93 e 0.98, respectivamente.

A tabela 2 mostra os resultados obtidos do classificador com o treinamento dos dados da primeira sessão, sendo a validação realizada para as quatro sessões restantes. Pode-se observar que houve uma tendência de aumento da porcentagem de acerto da classificação com o passar das sessões, principalmente observado entre a 2ª e 5ª sessões. Os sujeitos S1 e S3 apresentaram um aumento progressivo ao longo de todas as sessões.

Tabela 1. Taxa de acerto do classificador SVM com treinamento de 4 sessões e a validação com a quinta sessão.

Sujeito	Taxa de acerto
s1	0,95
s2	0,70
s3	0,93
s4	0,98

Tabela 2: Taxa de acerto do classificador SVM com treinamento da primeira sessão e validação com as sessões remanescentes

Sujeito	Taxa de acerto			
	sessão 2	sessão 3	sessão 4	sessão 5
s1	0,56	0,67	0,84	0,87
s2	0,53	0,31	0,58	0,63
s3	0,46	0,53	0,70	0,93
s4	0,52	0,96	0,95	0,85

4 Discussão

Na tabela 1, pode-se observar que 3 indivíduos apresentaram taxas de acertos maiores que 90% com a análise realizada. Entretanto, um indivíduo apresentou uma porcentagem de acerto de 70%. Esta diferença pode estar relacionada a diversos fatores, que podem alterar a relação sinal ruído. Dentre eles podem-se citar fatores fisiológicos, como a capacidade de imaginação de cada indivíduo, nível de concentração e estresse durante a coleta. Indivíduos melhores imaginadores podem apresentar padrões de ativação cortical diferentes daqueles considerados piores imaginadores [15]. Os resultados da tabela 2 sugerem que, em geral, ocorre um aumento progressivo na taxa de acertos, podendo-se inferir que, ao longo das sessões, a capacidade dos indivíduos em realizar uma tarefa de imaginação específica foi-se aprimorando com o tempo. Estes resultados sugerem que tanto o treinamento da técnica quanto dos indivíduos favorecem a utilização de uma interface cérebro-máquina (ICM). Com o treinamento, os indivíduos aprendem a ativar áreas corticais específicas, aumentando a eficiência neural e a plasticidade cortical [16], favorecendo o vetor de características que vão servir como entrada do classificador. Como consequência das sessões de prática mental obteve-se um maior número de dados para o treinamento (s1 a s4) do classificador SVM, incrementando o seu desempenho (seletividade das classes) [13].

5 Conclusão

Neste estudo, foi proposta a MSC na banda delta (0.1 a 1 Hz) associada à SVM para classificar sinais de EEG relacionados à imaginação motora, diferenciando-os daqueles gerados durante a atividade cortical espontânea. Pode-se observar que há um aumento da taxa de acertos na classificação após um programa de treinamento baseado em IM. Estes resultados sugerem que as técnicas empregadas neste estudo podem ser utilizadas no futuro para o acionamento de uma ICM e que o treinamento – do sistema e do indivíduo – estão intrinsecamente relacionados.

6 Agradecimentos

Agradecimentos pelo apoio financeiro para CAPES, FAMEMIG, CNPq.

7 Referencias

- [1] Hoffmann, U., Vesin, J.M., Ebrahimi, T., Recent Advances in Brain-Computer Interfaces. **Signal Processing Institute. Ecole Polytechnique Federale de Lausanne (EPFL)**, (2007).
- [2] Yang, Y., Zhang, X., Study on Pattern Recognition of EEG Based on Imagination and Hand Movement. **Proceedings of the 2009 IEEE. International Conference on Robotics and Biomimetics**, (2009) 19-23
- [3] Lotte, F., Congedo, M., L'Ecuyer, A., Lamarche, F., Arnaldi, B., Topical Review, A review of classification algorithms for EEG-based brain-computer interfaces, **Journal of Neural Engineering**, 4 (2007), R1-R13.
- [4] Ahmadi, M., Erfanian, A., An On-Line BCI System for Hand Movement Control Using Real-Time Recurrent Probabilistic Neural Network Proceedings of the 4th International FrD3.7 **IEEE EMBS Conference on Neural Engineering Antalya**, 29 (2009), 367-370.
- [5] Ming, D. et al., ICA-SVM Combination Algorithm for Identification of Motor Imagery Potentials. **IEEE CIMSA**, (2010).
- [6] Santos-Filho, S.A.S., Magnitude quadrática da coerência na detecção a Imaginação do Movimento para aplicação em Interface Cérebro-Máquina. Tese de doutorado – Escola de Engenharia da Universidade Federal de Minas Gerais, 2010.
- [7] Gregg, M., Hall, C., Butler, A., The MIQ-RS: A Suitable Option for Examining Movement Imagery Ability. **eCAM Advance Access**, 26(2007),1-9.
- [8] Santos Filho, S.A., Tierra-Criollo, C.J.; Souza, A.P., Pinto, M.A.S., Lima, M.L.C., Manzano, G.M., “Magnitude Squared of Coherence to detect imaginary movement”, **EURASIP Journ. On Advances in Signal Processing**, v (2009), 1-12.
- [9] Simpson, D.M., Tierra-Criollo, C.J., Leite, R.T., Zayen, E.J.B., Infantosi, A.F.C., Objective response detection in an electroencephalogram during somatosensory stimulation. **Annals of Biomedical Engineering**, 28 (2000), 691–698.
- [10] Dobie A., Wilson M., Analysis of Auditory Evoked Potentials by Magnitude Squared Coherence, **Ear and Hearing**, 10 (1989), 2-13.
- [11] Miranda de Sá, A.M.F.L., Felix, L.B., Infantosi, A.F.C., A Matrix-Based Algorithm for Estimation Multiple Coherence of a Periodic Signal and Its Application to the Multichannel EEG During Sensory Stimulation. **IEEE Trans. Biomedical Eng.**, 51 (2004), 1140-1146.
- [12] Chapelle, O., Vapnik, Bousquet, O, Mukherjee, S., Choosing Multiple Parameters for Support Vector Machines. **Machine Learning**, 46 (2002), 131–159.
- [13] Christopher, B., A Tutorial on Support Vector Machines for Pattern Recognition. **Data Mining and Knowledge Discovery**, 2, 121–167 (1998).
- [14] Simon, H., **Neural Networks A comprehensive Foundation**. Second Edition, **Prentice Hall**, (1999)
- [15] Cathy, M., Stinear, C.M., Byblow, W.D., Steyvers, M., Levin, O., Swinnen, S.P., Kinesthetic, but not visual, motor imagery modulates corticomotor excitability. **Exp Brain Res**, 168 (2006), 157–164.
- [16] Neubauer, A.C. & Fink, A., Intelligence and neural efficiency. **Neuroscience and Biobehavioral Reviews**, 33 (2009), 1004–1023.