

IMPLEMENTAÇÃO DE CLASSIFICADOR DE TAREFAS MENTAIS BASEADO EM EEG

André Freitas Barbosa¹, Bryan C. Souza², Antônio Pereira² e Adelardo A.D. de Medeiros¹

¹Laboratório de Robótica, Departamento de Engenharia de Computação e Automação, Universidade Federal do Rio Grande do Norte, CEP 59078-900, Natal

²Laboratório do Sono, Centro de Estudos e Pesquisa Prof. Cesar Timo-Iaria – IINN-ELS, R. Prof. Francisco Luciano de Oliveira, 2460. Candelária – 59066-060, Natal
afreitasb@gmail.com

Abstract – Brain-Machine Interfaces (BMIs) provide direct communication between the brain and external devices. They can be used to restore or augment human motor function and have been the focus of great interest in the last two decades in parallel with steady advances in microelectronics and our general understanding of the brain. In general, BMIs can be classified in invasive and non-invasive, depending on the need for surgical access to position the electrodes that will record the activity of neural ensembles. In the current work, we propose a new method for controlling a non-invasive, EEG-based, three class BMI, using motor imagery. For the classifier, we used an artificial neural network (ANN) implementation that learned to distinguish among three task-related EEG patterns.

Key-words – Neural Networks, Brain-Machine Interface, EEG

Resumo – Interfaces Cérebro-Máquina (ICMs) provêm comunicação direta entre o cérebro e dispositivos externos. Elas podem ser usadas para restaurar ou aumentar funcionamento motor humano e tem sido foco de grande interesse nas últimas duas décadas em paralelo com avanços consistentes em microeletrônica e do nosso entendimento geral do cérebro. Em geral, ICMs podem ser classificadas em invasivas e não-invasivas, dependendo da necessidade de acesso através de cirurgia para o posicionamento dos eletrodos que irão registrar a atividade de agrupamento neuronais. Neste trabalho nós propomos um novo método para controlar uma interface não-invasiva, baseada em EEG, de três classes, utilizando imagética motora. Para a classificação, utilizamos uma implementação de rede neural artificial (RNA) que aprendeu a distinguir entre os três padrões de EEG relacionados com as tarefas.

Palavras-chave – Redes Neurais, Interface Cérebro-Máquina, EEG.

1. Introdução

Uma Interface Cérebro-Máquina (ou interface cérebro-computador) é um sistema computacional capaz de interpretar informação codificada na atividade elétrica de grupos neuronais para controlar um dispositivo artificial, seja ele um computador, uma cadeira de rodas, ou até mesmo um braço mecânico. Dessa forma, é criado um canal de comunicação com atuadores artificiais que independe da ativação de músculos esqueléticos estriados [1]. O principal objetivo desta tecnologia é restaurar ou ampliar funções motoras em seres humanos.

Existem basicamente duas categorias de ICMs, levando em consideração a forma de acesso ao sinal cerebral: ICMs invasivas e não-invasivas. A primeira envolve algum tipo de procedimento cirúrgico para inserção dos eletrodos de registro no parênquima cerebral, para captar os sinais elétricos de grupos neuronais no cérebro. Já as não-invasivas, como o próprio nome diz, não necessitam de procedimentos cirúrgicos importantes. Por exporem o sujeito ao risco cirúrgico, é muito raro ter humanos se voluntariando como sujeitos experimentais de Interfaces Cérebro-Máquina invasivas.

As ICMs não-invasivas, por outro lado, pela sua natureza, têm se beneficiado da maior disponibilidade de dados em seres humanos. Apesar de poderem obter dados a partir de registros com as técnicas de eletroencefalografia (EEG), magnetoencefalografia (MEG) e imageamento por ressonância

magnética funcional (fMRI), a maioria esmagadora dos trabalhos [2-7] é feita com base na primeira forma de aquisição.

Nesse trabalho, desenvolvemos uma Interface Cérebro-Máquina não-invasiva, utilizando o EEG como método de aquisição de sinais neuronais. Nosso objetivo é avaliar a possibilidade de utilizar padrões de atividade neuronal derivados, exclusivamente, de tarefas de imagética motora, sem necessidade da ativação de grupos musculares durante sua execução.

2. Metodologia

Para aquisição do sinal eletroencefalográfico foi utilizado um aparelho de EEG (BrainNet BNT-36) de 22 canais, com uma frequência de amostragem de 400 Hz e um filtro notch em 60 Hz. Os eletrodos foram posicionados no escalpo de dois voluntários saudáveis (dois homens destros), de acordo com o padrão 10/20. Os sujeitos realizaram 3 sessões, com 42 *trials* cada, onde cada *trial* era composto pela descrição da tarefa a ser executada (duração de 3 segundos), seguida de um intervalo para execução da tarefa (7s) e, por fim, apresentação de uma tela de descanso (2s). Em cada sessão, as seguintes tarefas eram apresentadas aleatoriamente (14 vezes por tarefa): imaginação de movimento da mão esquerda, imaginação de movimento da mão direita e operação matemática de soma. Todas as tarefas eram executadas continuamente, a partir de um comando apresentado em um monitor de computador, até o aparecimento da tela de descanso. No intervalo entre as sessões, os sujeitos tinham um intervalo de 5 minutos para descanso.

Depois de terminada a fase de aquisição, iniciou-se a fase de processamento e classificação off-line, realizada integralmente no ambiente do software MATLAB®. Inicialmente, foi feita a extração de atributos, calculando o espectro de potência a cada 200 pontos (500ms de amostra) para cada um dos canais, durante o intervalo de execução de tarefa, utilizando a função *pwelch()*. Em seguida, calculou-se o valor acumulado dessa potência para cada uma das cinco bandas fundamentais de EEG: Delta (0.5-4 Hz), Teta (4-7 Hz), Alfa (7-14 Hz), Beta (14-20 Hz) e Gama (20-50 Hz). Assim, cada padrão de classificação foi composto por 110 atributos (22 canais x 5 bandas), todos previamente normalizados. Após extrair as características do sinal, o próximo passo foi utilizá-las para treinar um classificador baseado em redes neurais artificiais do tipo *MultiLayer Perceptron* (MLP). Foram escolhidas, arbitrariamente, dois tipos de arquitetura para a rede: com uma camada oculta (80 neurônios) e duas camadas ocultas (50 na primeira e 30 na segunda). Essas redes foram utilizadas para gerar dois tipos de classificadores: ternários (todas as tarefas) e binário (par de tarefas). Todas as redes foram treinadas com uma taxa de aprendizado de 0.01, utilizando o método *Powell-Beale* e validadas através do *10-fold cross-validation*.

3. Resultados

Em geral, os classificadores ternários obtiveram dificuldade em distinguir as tarefas, especialmente para as tarefas de imagética motora relacionadas com movimentos das mãos. Em ambos os sujeitos, as taxas de acerto médio foram inferiores a 60%. Entretanto, ao analisarmos as matrizes de confusão, é possível observar uma maior taxa de acerto para a tarefa de soma algébrica, enquanto que as tarefas de imagética motora apresentam uma alta taxa de colisão entre si. Apesar da taxa de acerto do Sujeito 02 ser bem baixa, um teste t mostrou que a rede está operacional, já que foi obtido um valor de $p < 0.001$ quando comparado com a condição aleatória. Todos os resultados abaixo foram obtidos com a arquitetura com duas camadas ocultas. No entanto, não houve diferenças significativas entre as duas arquiteturas (teste t; $p > 0.05$).

AM= 54.2%	ME	MD	Soma
ME	0.45	0.33	0.22
MD	0.22	0.49	0.19
Soma	0.15	0.16	0.68

Tabela 1: Resultado para classificador ternário do Sujeito 01. AM: Acerto Médio; ME: Imaginação de mão esquerda; MD: Imaginação de mão direita.

AM= 42.9%	ME	MD	Soma
ME	0.38	0.35	0.27
MD	0.29	0.44	0.27
Soma	0.27	0.26	0.47

Tabela 2: Resultado para classificador ternário do Sujeito 02.

Como era o esperado, as redes neurais treinadas como classificadores binários, conseguiram taxas de acerto relativamente mais altas. Aqui, também é possível ver uma dificuldade comparativamente maior em separar as duas tarefas de imaginação de movimento, tanto que a rede neural foi incapaz de aprender a classificar corretamente ($p > 0.05$ quando comparado com o acaso).

AM=57.8%	ME	MD
ME	0.55	0.45
MD	0.4	0.6

Tabela 3: Resultado para classificador binário do Sujeito 01: Mão Esquerda x Mão Direita.

AM=70.8%	ME	Soma
ME	0.74	0.26
Soma	0.32	0.68

Tabela 4: Resultado para classificador binário do Sujeito 01: Mão Esquerda x Soma.

AM=75.4%	MD	Soma
MD	0.76	0.24
Soma	0.26	0.74

Tabela 5: Resultado para classificador binário do Sujeito 01: Mão Direita x Soma.

AM=52.2%	ME	MD
ME	0.52	0.48
MD	0.47	0.53

Tabela 6: Resultado para classificador binário do Sujeito 02: Mão Esquerda x Mão Direita.

AM=60.5%	ME	Soma
ME	0.61	0.39
Soma	0.4	0.6

Tabela 7: Resultado para classificador binário do Sujeito 02: Mão Esquerda x Soma.

AM=62.7%	MD	Soma
MD	0.67	0.33
Soma	0.41	0.59

Tabela 8: Resultado para classificador binário do Sujeito 02: Mão Direita x Soma.

Entretanto, nem a taxa de acerto nem a matriz de confusão dão uma real dimensão do que pode ser feito com ICMs. Wolpaw e colaboradores [8] sugeriram uma medida nova para indicar o poder de uma Interface Cérebro-Máquina: a taxa de transferência de informação (equação abaixo). Nessa equação, a taxa de transferência B (medida em bits/segundo) é função do número de tarefas N, da taxa de acerto P e da velocidade do funcionamento da interface V, que nesse trabalho está caracterizada pelo tamanho da janela (500 ms).

$$B = \left[\log_2 N + P \log_2 P + (1 - P) \log_2 \left(\frac{1 - P}{N - 1} \right) \right]$$

	Ternário	Binário: MExMD	Binário: MExSoma	Binário: MDxSoma
Sujeito 01	0.27	0.06	0.27	0.4
Sujeito 02	0.07	0.01	0.07	0.11

Tabela 9- Taxa de transferência de informação (em bit/segundo) para cada uma das interfaces.

4. Discussão

As baixas taxas de acerto, que mesmo para os classificadores binários não passaram dos 75%, não são inferiores do que é encontrado na literatura [4]. A diferença entre os Sujeitos 01 e 02 é explicada analisando os depoimentos concedidos pelos sujeitos no intervalo entre as sessões: enquanto o Sujeito 01 se manteve alerta durante todo o tempo do experimento, o Sujeito 02 afirmou ter sono e dificuldade de se concentrar na realização das tarefas, o que certamente piorou seu desempenho.

Os resultados dos classificadores binários ajudam a corroborar o que é sugerido pelos classificadores ternários: existe um grande grau de similaridade entre os padrões de imagética motora relacionados com movimento das mãos. A localização espacial das fontes é muito provavelmente a maior responsável por essa semelhança, uma vez que ambas as tarefas ativam regiões motoras localizadas proximamente, embora em hemisférios diferentes.

5. Conclusão

As taxas de transferência de informação estão compatíveis com os valores encontrados na literatura (10-25 bits/minuto ou 0,17-0,42 bit/segundo) [9], o que mostra que a abordagem escolhida tem um desempenho no mínimo regular.

O uso de classificadores de duas classes se mostrou pelo menos tão eficiente quanto o de três. Na verdade, uma vez que o primeiro teve uma taxa de acerto maior, pode-se afirmar que o seu uso seria mais confiável e, no mínimo, tão útil quanto o do ternário. O uso de Máquinas de Comitê com classificadores binários como especialistas pode ser uma ferramenta para ampliar ainda mais a eficiência da Interface Cérebro-Máquina.

Apesar de funcionar no modo *off-line*, o trabalho é inédito, por utilizar RNAs para classificar padrões derivados da imagética motora. O objetivo é ampliar a quantidade de sujeitos para obter uma maior generalização dos resultados obtidos.

Agradecimentos: Os autores agradecem o apoio da Associação Alberto Santos Dumont para Apoio à Pesquisa.

Referências:

- [1] J.R. Wolpaw, Brain-computer interfaces as new brain output pathways, **The Journal of Physiology**, vol. 579(2007), 613–619.
- [2] N. Birbaumer, A. Kübler, N. Ghanayim, T. Hinterberger, J. Perelmouter, J. Kaiser, I. Iversen, B. Kotchoubey, N. Neumann, e H. Flor, The thought translation device (TTD) for completely paralyzed patients, **IEEE Transactions on Rehabilitation Engineering: A Publication of the IEEE Engineering in Medicine and Biology Society**, 8 (2000), 190–193.
- [3] B. Obermaier, C. Neuper, C. Guger, e G. Pfurtscheller, Information transfer rate in a five-classes brain-computer interface, **IEEE Transactions on Neural Systems and Rehabilitation Engineering: A Publication of the IEEE Engineering in Medicine and Biology Society**, 9 (2001), 283–288.
- [4] J. Kronegg, G. Chanel, S. Voloshynovskiy, e T. Pun, EEG-Based Synchronized Brain-Computer Interfaces: A Model for Optimizing the Number of Mental Tasks, **Neural Systems and Rehabilitation Engineering**, 15 (2007), 50–58.
- [5] J. Vidal, Real-time detection of brain events in EEG, **Proceedings of the IEEE**, 65 (1977), 633–641.
- [6] J. Vidal, Toward direct brain-computer communication, **Annual Review of Biophysics and Bioengineering**, 2 (1973), 157–180.
- [7] T. Elbert, B. Rockstroh, W. Lutzenberger, e N. Birbaumer, Biofeedback of slow cortical potentials. I, **Electroencephalography and Clinical Neurophysiology**, 48 (1980), 293–301.
- [8] J.R. Wolpaw, H. Ramoser, D.J. McFarland, e G. Pfurtscheller, EEG-based communication: improved accuracy by response verification, **IEEE Transactions on Rehabilitation Engineering: A Publication of the IEEE Engineering in Medicine and Biology Society**, 6 (1998), 326–333.
- [9] J.R. Wolpaw, N. Birbaumer, D.J. McFarland, G. Pfurtscheller, e T.M. Vaughan, Brain-computer interfaces for communication and control, **Clinical Neurophysiology: Official Journal of the International Federation of Clinical Neurophysiology**, 113 (2002), 767–791.