

Análise de um classificador neural de sinais de EEG na detecção de movimentos

Valfredo Pilla Jr.¹, Heitor S. Lopes²

^{1,2} Departamento de Eletrônica e Laboratório de Bioinformática / CPGEI
Centro Federal de Educação Tecnológica do Paraná (CEFET-PR)
Av 7 de setembro, 3165 – 80230-901, Curitiba (PR), Brasil
Fone (0**41) 310-4616, Fax (0**41) 310-4187
valfredo@daeln.cefetpr.br, hslopes@cpgei.cefetpr.br

Resumo – Neste trabalho buscou-se detectar o movimento da mão de voluntários através do sinal de EEG. A detecção de movimentos pode ser usada como base da elaboração de sistemas de interface cérebro-computador (BCI). Buscou-se separar da atividade de fundo do EEG a dessincronização relacionada ao movimento (MRD) do ritmo mu produzida no córtex sensorimotor contralateral pelo movimento da mão direita. Os voluntários realizaram uma das duas tarefas: (a) um único movimento por tentativa; (b) repetição do movimento. A variação temporal do espectro da banda mu da derivação eletroencefalográfica amostrada foi computada *off-line* através da FFT. Esta resposta foi utilizada como predicado no treinamento e teste de classificadores baseados em uma rede neural Kohonen-LVQ. Os classificadores foram treinados por sessão, por tarefa e por voluntário. O desempenho foi medido pela média geométrica dos índices de sensibilidade e especificidade. O melhor desempenho de detecção foi de 88% para a tarefa com movimento único e de 78% para a tarefa com repetição de movimentos, com um desempenho médio de 66% para ambas as tarefas. Foram necessárias apenas 3 subclasses da rede neural para cada classe treinada. Para a obtenção dos melhores resultados, foi suficiente uma constante de aprendizado de 0,01 e um número de épocas de treinamento definido por 250 x (número total de subclasses).

Palavras-chave: BCI, EEG, LVQ, MRD, processamento de sinais, reconhecimento de padrões, redes neurais.

Abstract - In this work, we aimed to detect the hand movement of volunteers by means of analyzing the EEG signal. The movement detection can be used as the base for a brain-computer interface (BCI) system. The objective is to distinguish from the background activity of the EEG, the non-averaged movement-related desynchronization (MRD) of the mu rhythm, produced in the contralateral sensorimotor cortex by means of a movement of the right hand. The volunteers were asked to do one of two tasks: (a) only one movement by trial; (b) repetition of movements. The time response of the spectrum of the mu band of one electroencephalographic lead was computed with the FFT. This response was used for training and testing a Kohonen-LVQ neural network classifier. The classifiers were trained by session, by task and by volunteer. The performance was evaluated using the geometric mean of the sensibility and specificity indexes. The best detection performance was 88% for the single movement task and 78% for repetition of movements, with an average of 66% for both tasks. To achieve the best results, the classifier used only 3 subclasses for each class and a constant learning rate of 0.01 with the number of training epochs calculated by the relation of 250 x (total number of subclasses).

Key-words: BCI, EEG, LVQ, MRD, neural networks, signal processing, pattern recognition.

Introdução

O movimentos dos membros produzem alterações no sinal eletroencefalográfico, especialmente na região do córtex sensorimotor contralateral ao membro. Entre estas alterações apresenta-se a Dessincronização Relacionada ao Movimento (MRD - *Movement-Related Desynchronization*) que pode ser observada na banda mu (8-12 Hz) [1, 2, 3, 4, 5].

Este trabalho tem como objetivo desenvolver um sistema classificador capaz de identificar a presença da MRD e, portanto, a realização do movimento de um membro, em meio à atividade de fundo do sinal de EEG.

Os experimentos realizados avaliaram duas formas diferentes de produzir a MRD. Para tanto, foram utilizadas duas tarefas que envolvem o movimento da

mão direita. O movimento foi definido como a elevação da mão em torno do pulso, para cima e de volta para a posição de repouso. A primeira tarefa foi definida como a realização de um único movimento por tentativa; a segunda tarefa envolveu a repetição dos movimentos ao longo da tentativa.

Este trabalho também objetivou avaliar o desempenho de uma rede neural Kohonen-LVQ (*Learning Vector Quantization*) como um classificador de sinais eletroencefalográficos.

A técnica empregada aqui será aplicada posteriormente na implementação de uma Interface Cérebro-Computador (BCI - *Brain-Computer Interface*) [6]. As BCIs podem ser utilizadas na elaboração de dispositivos de auxílio aos portadores de deficiências físicas [7]. As técnicas utilizadas na elaboração de BCIs utilizam-se do reconhecimento de padrões específicos

apresentados no sinal eletroencefalográfico do usuário do sistema [8].

Metodologia

A configuração experimental utilizada na coleta de sinais dos voluntários é apresentada na figura 1.

O EEG foi coletado do escalpo através de eletrodos posicionados na região próxima à da derivação C3 (conforme o Sistema 10/20 da Federação Internacional de Eletroencefalografia). O primeiro eletrodo (C3a) foi colocado em posição 25 mm anterior à C3 e o segundo (C3p) na mesma distância, em posição posterior. O eletrodo de referência foi posicionado na orelha esquerda. Um amplificador diferencial (ganho de 30.000 V/V) também filtra o sinal de EEG na banda de 8-100Hz. A taxa de amostragem inicial foi de 1280Hz, com resolução de 16 bits.

Em um sessão de coleta de sinais, a mesma tarefa foi executada em todas as tentativas (movimento único ou repetição dos movimentos). Pelo menos 50 tentativas válidas, com duração de 20s cada, foram coletadas de cada voluntário. As tentativas válidas foram aquelas em que artefatos indesejados não foram visualmente detectados. Após a sessão, todas as amostras foram novamente inspecionadas para eliminar as que ainda apresentassem artefatos indesejados.

Uma sequência de eventos específica para cada tarefa foi apresentada na tela de um computador pessoal. Estas sinalizações orientavam os voluntários ao longo da tarefa. Para a primeira tarefa (movimento único), uma seta era apresentada na tela em $t=6s$ para indicar que o movimento deveria ser realizado imediatamente. Para a segunda tarefa, a seta era apresentada pela primeira vez em $t=11s$, indicando que o voluntário deveria iniciar os movimentos. A seta era reapresentada em intervalos de 1s até $t=19s$, indicando quando o movimento deveria ser repetido. Todas as tentativas tiveram uma duração total de 20s.

Todos os voluntários realizaram ambas as tarefas porém, em sessões diferentes.

Em todas as sessões, os voluntários permaneceram confortavelmente sentados em uma cadeira reclinada. As luzes permaneceram apagadas e a temperatura da sala foi mantida inferior a 25 °C. Os voluntários deviam permanecer mental e fisicamente relaxados porém atentos, olhando diretamente para a tela do computador.

O movimento da mão foi realizado na forma de um giro para cima em torno do pulso, afastando a mão de seu apoio seguido de um movimento para baixo, retornando-a à posição de descanso. A tarefa deveria ser realizada no intervalo de 0,4 a 0,9s, sincronizada pela informação visual apresentada na tela do computador. Todos os voluntários foram submetidos a uma sessão de treinamento para a familiarização com os procedimentos.

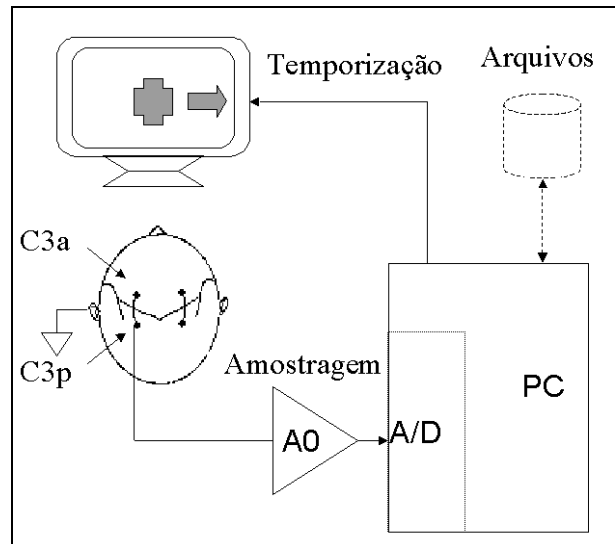


Figura 1 – Configuração experimental

Treze voluntários, 12 homens e 1 mulher, participaram dos experimentos. Todos eram destros e pertenciam à faixa etária dos 22 aos 37 anos.

Processamento dos Sinais

Os sinais coletados dos voluntários foram processados *offline*. Os sinais originais foram filtrados digitalmente por um passa-baixas FIR de janela de Hanning com frequência de corte de 128Hz e ordem 128. O sinal amostrado foi então dizimado, reduzindo-se a taxa de amostragem inicial de 1280Hz para 256 Hz. Em seguida, a banda mu foi extraída com um filtro digital FIR de janela de Hanning de ordem 64, com banda de 7-13Hz. Utilizando este sinal filtrado, a resposta temporal do espectro da banda mu foi calculada a intervalos de 0,125s (32 amostras) usando uma janela de 1s (256 amostras). Para cada janela, a FFT foi computada [9]. Assim, a k -ésima resposta temporal $y(k)$ da banda mu foi definida como a média do valor absoluto das componentes espectrais das componentes de 8-12Hz, tomada para a k -ésima janela de uma dada tentativa.

A resposta temporal do espectro da banda mu foi computado para todas as tentativas de cada sessão da qual os voluntários participaram.

A figura 2 apresenta a resposta temporal do espectro da banda mu, como a média de sessão, para dois voluntários diferentes. Nesta figura, pode-se notar a presença de um vale entre $t \approx 6s$ e $t \approx 8s$ (para a tarefa com movimento único) para ambos os voluntários. Este vale corresponde à presença da MRD da banda mu associada ao movimento. Nas sessões com movimentos repetidos, para o primeiro voluntário, pode-se notar a presença do vale a partir de $t \approx 11s$, persistindo até o último movimento, em $t \approx 19s$. Para o segundo voluntário, a MRD desapareceu prematuramente, provavelmente devido ao seu excessivo estado de relaxamento durante a sessão, não sendo este voluntário capaz de repetir os movimentos de forma sincronizada com as sinalizações.

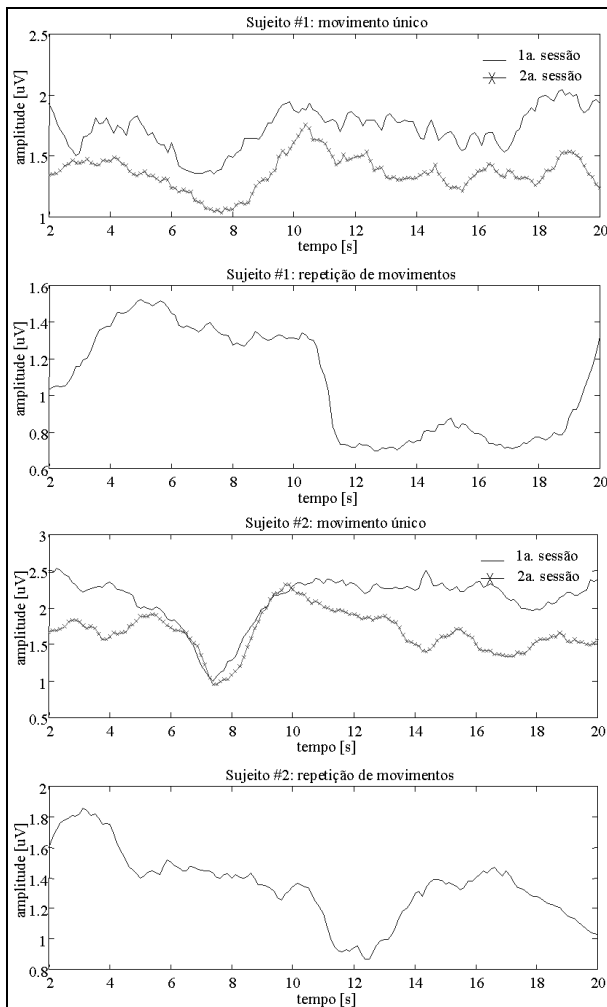


Figura 2: Resposta temporal média do espectro da banda mu. Acima: voluntário #1; abaixo: voluntário #2

Treinamento da Rede Neural

O conjunto de dados utilizado no treinamento e teste do classificador foi constituído por vetores com dimensão de 9 amostras sequenciais tomadas como janelas da resposta temporal do espectro da banda mu. O conjunto de dados foi dividido em duas classes, “com movimento” (CM) e “atividade de fundo” (AF), onde o primeiro corresponde às janelas onde a MRD esteve presente.

Para a tarefa com movimento único, as janelas para a classe CM foram tomadas entre $t=6,5s$ e $t=7,5s$ e, para a classe AF, após $t=10s$. O nível de significância $p \gg 5\%$ foi usado como critério para selecionar as janelas para a classe AF. O índice foi calculado através da análise da variância (ANOVA) [10] usando o intervalo $t=10s$ a $t=20s$ como referência.

A proporção de uma janela de CM para três de AF tomada de cada tentativa foi usada na composição do conjunto de teste e do conjunto de treinamento de uma dada sessão.

Para a tarefa com múltiplos movimentos, a classe CM foi tomada da resposta temporal após $t=11s$, usando o critério de significância de $p \leq 5\%$. As janelas para a classe AF foram tomadas no intervalo $t=2s$ a $t=10s$, usando também $p \gg 5\%$. Em ambos os casos, a

referência foi o intervalo com atividade de fundo, isto é, entre $t=2s$ e $t=10s$. Uma proporção de 3 CM para 3 AF foi utilizada para todas as tentativas nesta tarefa para a composição dos conjuntos de treinamento e teste.

O classificador utilizado é constituído por uma rede neural Kohonen LVQ (*Learning Vector Quantization*), tipo 2 [11], cuja estrutura é ilustrada na figura 3. Este classificador é baseado em agrupamento (*clustering*) com aprendizado supervisionado e utiliza uma arquitetura de quantização de vetores para aproximar os limites ótimos de decisão de um classificador Bayesiano [12, 13]. Ele é constituído por duas camadas. A primeira é denominada camada competitiva. Nesta camada, a métrica Euclidiana (módulo DIST da figura 3) determina a distância entre o padrão de entrada x e os $s=(n_1+n_2)$ vetores de referência (R_i). O conjunto de vetores de referência, definidos através do treinamento da rede neural são constituídos pelas n_1 subclasses representando a classe CM e n_2 subclasses representando a classe AF. Um algoritmo “the winner takes it all” (“o vencedor leva tudo”) ativa (“1”) um único neurônio dentre os n_1 neurônios da classe CM ou dentre os n_2 neurônios da classe AF. Todos os demais neurônios permanecem desativados (“0”). O único vetor de referência ativado corresponde ao mais próximo do padrão de entrada. A segunda camada é linear e associa com peso “1” cada subclasse à sua classe correspondente. Assim, se for aplicado um padrão x à entrada do classificador, somente uma classe (CM ou AF) é ativada.

As redes foram treinadas por sessão (ou grupo de sessões se um dado voluntário tiver participado de mais de uma sessão realizando a mesma tarefa), por tarefa e por voluntário. Dois terços dos dados foram usados na composição do conjunto de treinamento e o terço restante foi utilizado para teste do classificador.

O critério de avaliação do desempenho das redes neurais foi definido como o número de classificações corretas [14], ou seja, como a relação entre o número de positivos verdadeiros (presença da MRD) e de negativos verdadeiros (presença da atividade de fundo) perante os casos de erro de classificação. Medidas comuns de desempenho são a sensibilidade e a especificidade, definidas como nas equações 1 e 2, respectivamente:

$$se(i) = \frac{tp(i)}{tp(i) + fn(i)} \quad (1)$$

$$sp(i) = \frac{tn(i)}{tn(i) + fp(i)} \quad (2)$$

onde:

- i - i -ésima época de treinamento
- se - Sensibilidade
- tp - (positivos verdadeiros) número de classificações corretas para a classe CM
- fn - (negativos falsos) número de classificações incorretas para a classe CM
- sp - Especificidade
- tn - (negativos verdadeiros) número de classificações corretas para a classe AF

fp - (positivos falsos) número de classificações incorretas para a classe AF

Sensibilidade e especificidade identificam, respectivamente, a proporção de casos da classe CM e da classe AF que são corretamente classificados como tais. Estas duas medidas foram calculadas para o conjunto de teste a cada época de treinamento. Usando estas medidas, um índice de desempenho (de) da i -ésima época de treinamento da rede neural foi calculado através da equação 3:

$$de(i) = \sqrt{se(i) \cdot es(i)} \quad (3)$$

O índice de é normalizado na faixa [0..1], onde 0 é definido como o pior desempenho (0% de classificações corretas) e 1 o melhor (100%). Este índice facilita a análise de desempenho do treinamento da rede neural pois o mesmo reúne os índices sensibilidade e especificidade.

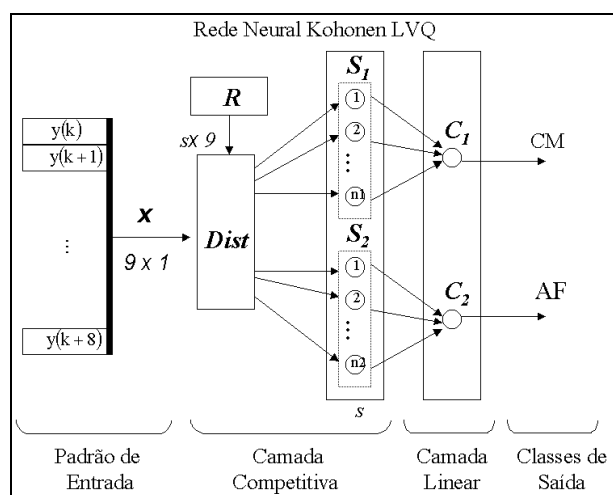


Figura 3 – Estrutura da rede neural LVQ

Resultados

Os parâmetros a serem ajustados para o treinamento de uma rede neural LVQ são a taxa de aprendizado α e o número de épocas de treinamento. O treinamento objetiva encontrar os melhores vetores de referência para cada classe. Segundo a literatura, o número ótimo de épocas de treinamento para uma rede LVQ está situado entre 50 a 200 vezes o número total de subclasses. Neste trabalho, verificou-se que a relação de 250 vezes o número de subclasses foi suficiente para alcançar o melhor desempenho.

A taxa de aprendizado foi empiricamente ajustada para 0,01, visto que experimentos preliminares mostraram que os melhores resultados foram obtidos com α na faixa de 0,005 a 0,02.

Para encontrar a melhor combinação de vetores de referência por classe (CM e AF), foram experimentadas todas as 36 possíveis combinações de 1 a 6 vetores de referência por classe. Cada treinamento foi repetido três vezes para todos os voluntários. Os

melhores resultados para cada voluntário são apresentados na tabela 1.

Da tabela 1 é possível verificar que nem todos os voluntários tiveram seus sinais utilizados no experimento. Isto aconteceu pois nesses casos a inspeção visual dos sinais auxiliada pela análise da variância não apontou a presença de um padrão. Nesses casos os sinais foram descartados. Os dados apresentados na tabela 1 são resumidos na tabela 2, na qual o desempenho médio é apresentado.

Discussão e Conclusões

A resposta temporal média do espectro permitiu a observação da MRD da banda mu, como esperado.

Os classificadores (rede neural LVQ) treinados para ambas as tarefas obtiveram aproximadamente o mesmo desempenho (em torno de 66%), em média. Isto significa que a construção de um conjunto de comandos associado à detecção de movimentos (objetivando um sistema BCI) é factível e pode ser baseado na tarefa com movimento único. Para ambas as tarefas a estrutura do classificador é similar, sendo necessárias, em média, 3 subclasses para cada classe (CM ou AF).

Tabela 1 – Resultados do treinamento das redes LVQ

Voluntário #	Movimento	Subclasses		Desempenho [%]
		AF	CM	
1	Único	6	5	64,0
1	Repetição	3	4	78,1
2	Único	3	1	88,2
2	Repetição	4	1	72,2
3	Único	4	2	65,6
3	Repetição	1	1	71,7
4	Único	2	2	63,2
5	Único	2	5	57,6
5	Repetição	5	5	62,1
6	Único	4	3	62,1
6	Repetição	4	3	59,1
7	Único	1	3	55,9
7	Repetição	2	1	70,8
8	Repetição	2	4	60,1
9	Repetição	3	2	53,8
13	Único	5	3	73,8
13	Repetição	5	5	60,6

A rede neural Kohonen-LVQ foi adequada à identificação das duas classes de sinais eletroencefalográficos aplicados neste trabalho. Isto sugere que este classificador é suficientemente robusto para tais aplicações, considerando que as amostras de EEG utilizadas eram muito ruidosas. A fase de treinamento foi relativamente rápida, devido ao pequeno número de épocas de treinamento necessários e ao pequeno número de neurônios (subclasses). Este é um predicado crucial para classificadores que precisam ser adaptados em tempo real, como em aplicações de Interface Cérebro-Computador (BCI).

Os resultados obtidos neste trabalho encorajam desenvolvimentos posteriores da metodologia relatada aqui, aplicadas no desenvolvimento de tecnologia BCI.

Tabela 2 – Desempenho médio comparativo

Movimento	Desempenho [%]		
	Médio	Máx.	Min.
Único	66,3 ^(*)	88,2	55,9
Repetido	65,4 ^(*)	78,1	53,8
Movimento	Subclasse: AF		
	Médio	Máx.	Min.
Único	3,4	6	1
Repetido	3,2	5	1
Movimento	Subclasse: CM		
	Médio	Máx.	Min.
Único	3	5	1
Repetido	2,9	5	1

(*) – significância (p) 84%

Referências

- [1] R. Nashmi, A. J. Mendonça and W. A. MacKay, "EEG rhythms of the sensorimotor region during hand movements", *Electroencephalography and Clinical Neurophysiology*, vol. 91, n. 6, pp. 456-467, 1994.
- [2] D. Flotzinger, J. Kalcher and G. Pfurtscheller, "EEG classification by learning vector quantization", *Biomedizinische Technik*, vol. 37, n. 12, pp. 303-309, 1992.
- [3] D. Flotzinger, G. Pfurtscheller, C. Neuper, J. Berger and W. Mohl, "Classification of non-averaged EEG data by learning quantization and the influence of signal preprocessing", *Medical and Biological Engineering and Computing*, vol. 32, pp. 571-576, 1994.
- [4] G. Pfurtscheller, D. Flotzinger and C. Neuper, "Differentiation between finger, toe and tongue movement in man based on 40 Hz EEG", *Electroencephalography and Clinical Neurophysiology*, vol. 90, n. 6, pp. 456-460, 1994.
- [5] G. Pfurtscheller, J. Kalcher, C. Neuper, D. Flotzinger and M. Pregenzer, "On-line EEG classification during externally-paced hand movements using a neural network-based classifier", *Electroencephalography and Clinical Neurophysiology*, vol. 99, n. 5, pp. 416-425, 1996.
- [6] V. Pilla Júnior, *Detecção de Padrões Eletroencefalográficos Relacionados ao Movimento para uma Interface Cérebro-Computador*. Curitiba, 1999. Dissertação (Mestre em Ciências) – Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial (CPGEI), CEFET-PR.
- [7] D. J. McFarland, A. T. Lefkowitz and J. R. Wolpaw, "Design and operation of an EEG-based brain-computer interface with digital signal processing technology", *Behavioral Research Methods, Instruments & Computers*, vol. 29, n. 3, p. 337-345, 1997.
- [8] T. M. Vaughan, J. R. Wolpaw and E. Donchin, "EEG-based communication: prospects and problems", *IEEE Transactions on Rehabilitation Engineering*, vol. 4, n. 4, pp. 425-430, 1996.
- [9] B. Boashah (Ed.), *Time-Frequency Signal Analysis: Methods and Applications*. Melbourne: Longman Cheshire, 1992.
- [10] T. H. Wonnacott e R. J. Wonnacott, R. J., *Introdução à Estatística*. 1ª edição. Rio de Janeiro: Livros Técnicos e Científicos, 1980.
- [11] T. Kohonen, *Self-Organizing Maps*. 2nd edition. Heidelberg: Springer-Verlag, 1997.
- [12] D. K. Ford, *Analysis of LVQ in the Context of Spontaneous EEG Signal Classification*. Fort Collins, 1996. Dissertation (Master of Science) – Department of Computer Science, Colorado State University.
- [13] M. Friedman, A. Kandel, *Introduction to Pattern Recognition: statistical, structural, neural and fuzzy logic approaches*. 2nd edition. Singapore: World Scientific, 1999.
- [14] D. J. Hand, *Construction and Assessment of Classification Rules*. Chichester: John Wiley & Sons, 1997.