

INTERFACE CÉREBRO-COMPUTADOR INDEPENDENTE DE VISÃO USANDO ATENÇÃO SELETIVA E ANÁLISE DE COMPONENTES PRINCIPAIS

ANA PAULA DE SOUZA^{*,†,‡}, LEONARDO BONATO FELIX[†], EDUARDO MAZONI A M MENDES[‡]

**Instituto de Ciências Exatas e Tecnológicas
Universidade Federal de Viçosa/Campus Florestal
Florestal, MG, Brasil*

*†Núcleo Interdisciplinar de Análise de Sinais
Departamento de Engenharia Elétrica
Universidade Federal de Viçosa
Viçosa, MG, Brasil*

*‡Programa de Pós-Graduação em Engenharia Elétrica
Universidade Federal de Minas Gerais
Belo Horizonte, MG, Brasil*

Email: ana.psouza@ufv.br, leobonato@ufv.br, emmendes@cpdee.ufmg.br

Abstract— Principal Component Analysis (PCA) has been used for filtering electroencephalogram signals with direct application to Brain Computer-Interface (BCI) so as to promote feature extraction and better detection. In this context, this work aims to apply PCA to signals of auditory evoked potential involving selective attention and compare the results to those originated from the signal classification without PCA. EEG from 14 subjects was collected during auditory stimulation and the classification was performed offline. Stimuli were AM tones with 500 Hz and 2000 Hz carriers (left and right ears, respectively) and modulation frequencies of 32 Hz in the left ear and 38 Hz in the right ear. The signals were recorded according to 10-20 international system and the electrodes T3, F3, P3, O1, T4, P4, O2, Fz and Pz were used in classification. With eleven principal components (PCs), 99% of the variance of data sample is explained. The reconstructed signals using these components were processed with spatial coherence and the obtained classification hit rate was 92.86%, considering 11.92s of signal and the obtained information transfer rate was 3.16 *bits/min*. On the other hand, without using the PCA, the hit rate and the information transfer rate are 82.14% and 1.89 *bits/min*, respectively. This seems to indicate that PCA analysis can be used to improve BCI performance when using auditory selective attention and spatial coherence.

Keywords— BCI, Selective Attention, Spatial Coherence, PCA

Resumo— A Análise de Componentes Principais (*Principal Component Analysis* - PCA) tem sido utilizada para a filtragem de sinais de eletroencefalograma (EEG) aplicados em Interfaces Cérebro-Computador (ICCs), permitindo uma melhor detecção e extração de características. Nesse sentido, o presente trabalho visa aplicar a PCA em sinais com potencial evocado auditivo envolvendo atenção seletiva e comparar com a classificação usando o sinal sem PCA. Para a verificação da ICC, o EEG de 14 voluntários foi coletado durante estimulação auditiva e a classificação foi feita offline. O estímulo utilizado foi um tom com modulação em amplitude (AM) com portadoras e moduladoras de 2 kHz e 38 Hz, para a orelha direita e 500 Hz e 32 Hz, para a orelha esquerda, respectivamente. Os sinais de EEG foram registrados de acordo com o sistema internacional 10-20 e, para a classificação, foram utilizados apenas os eletrodos T3, P3, F3, O1, P4, O2, T4, Pz e Fz. Considerando-se onze componentes principais (*Principal Components* - PCs), tem-se 99% da variância explicativa dos dados. Os sinais reconstruídos com essas componentes foram processados com a coerência espacial e apresentaram, na classificação, taxa de acerto de 92,86%, considerando-se 11,92s de sinal. A taxa de transferência de informação obtida com essa configuração foi de 3,16 *bits/min*. Considerando-se a classificação sem a utilização da PCA tem-se taxa de acerto de 82,14% e taxa de transferência de informação de 1,89 *bits/min*. Dessa forma, avaliando-se essas taxas, pode-se concluir que a aplicação da PCA promove uma melhor performance de uma ICC com atenção seletiva auditiva e coerência espacial.

Palavras-chave— ICC, Atenção Seletiva, Coerência Espacial, PCA

1 Introdução

A interface cérebro computador (ICC) permite a utilização de sinais cerebrais para o controle de dispositivos diversos (Riccio et al., 2012; Barbosa et al., 2016). Uma das formas mais populares de registro desses sinais é o eletroencefalograma (EEG). A aplicação do EEG em ICCs pode ser feita utilizando-se a resposta evocada diante de estimulações auditivas, visuais, somato-sensitivas, atividades motoras ou combinações desses estímulos (Halder et al., 2010; Kim et al., 2011; Barbosa

et al., 2016).

Muitas pesquisas têm avaliado a utilização do Potencial Evocado Auditivo (PEA) em sistemas de ICC com sons diversos, tais como modulação em amplitude (*Amplitude Modulation* - AM), modulação em frequência (*Frequency Modulation* - FM), combinação de tons AM e FM, voz humana, músicas, sons da natureza, dentre outros (Kim et al., 2011; Lopez-Gordo et al., 2012; Felix et al., 2014). Esses potenciais tem sido utilizados, pois permitem a implementação de ICCs que não necessitam do *feedback* visual ou motor,

contemplando, dessa forma, usuários que estão totalmente paralisados (Hong et al., 2009; Guo et al., 2012; Ranaudo, 2012; Halder et al., 2013).

Um dos potenciais utilizados é o proveniente do estímulo auditivo em regime permanente (*Auditory Steady-State Responses* - ASSR), que pode ser influenciado pelo foco da atenção (Chiappa, 1997; Kim et al., 2011; Ranaudo, 2012). Neste sentido, a investigação da ASSR e da atenção seletiva, aplicadas nas ICCs, exige processamento de sinais, tendo como objetivo o aumento da confiabilidade na detecção e reconhecimento de padrões da atividade cerebral analisada (Hoffmann et al., 2007; Halder et al., 2010; Ranaudo, 2012).

Várias técnicas têm sido aplicadas nos sinais utilizados em ICCs, tanto na extração de características, quanto na classificação dos potenciais evocados (Hoffmann et al., 2007; Kim et al., 2011; Riccio et al., 2012). Dentre essas técnicas tem-se a máquina de vetor de suporte (*Support Vector Machine* - SVM) (Hong et al., 2009; Nishikawa et al., 2013), a magnitude quadrática da coerência - MSC (Felix et al., 2015), filtros (Väljamäe et al., 2013; Barbosa et al., 2016), modelos autorregressivos (Higashi et al., 2011), análise de componentes principais (*Principal Component Analysis* - PCA) (Dähne et al., 2011; Moreira et al., 2014; Winkler et al., 2014), dentre outras.

A MSC tem se mostrado uma ferramenta robusta na detecção de potenciais diversos aplicados à ICC (Chen et al., 2014; Netto et al., 2014; Felix et al., 2015). Essa técnica, associada à localização espacial dos eletrodos utilizados (coerência espacial), tem sido eficiente na identificação do foco de atenção (Ranaudo, 2012; Felix et al., 2014). Da mesma forma, a PCA tem sido aplicada para melhorar a qualidade dos sinais analisados (Dähne et al., 2011; Moreira et al., 2014).

Neste contexto, o presente trabalho investiga a performance de uma ICC offline utilizando a PCA e a coerência espacial para a identificação da atenção seletiva auditiva. O desempenho será avaliado por meio da taxa de acerto, taxa de transferência de informação e a área abaixo da curva que são medidas comumente analisadas na literatura (Kim et al., 2011; Riccio et al., 2012; Felix et al., 2015).

2 Materiais e Métodos

2.1 Protocolo experimental

O EEG de 14 voluntários foi registrado no NIAS (Núcleo Interdisciplinar de Análise de Sinais) de acordo com protocolo aprovado pelo Comitê de Ética Local. Para a aquisição foi utilizado o amplificador BrainNet, com filtro passa-alta e passa-baixa de 0,1 Hz e 100 Hz, respectivamente, filtro notch de 60 Hz e frequência de amostragem de 600 Hz. No registro foram utilizados 23 eletrodos fixa-

dos de acordo com o sistema 10-20, com referência no eletrodo Oz e terra fixado na testa.

O estímulo considerado foi um tom AM, gerado digitalmente, com frequência de amostragem de 44100 Hz e profundidade de 100%. A intensidade sonora foi de 75 dB SPL (Nível de Pressão Sonora, do inglês Sound Pressure Level) e as frequências de portadora e moduladora foram de 2 kHz e 38 Hz, para a orelha direita e 500 kHz e 32 Hz para a orelha esquerda, respectivamente.

O protocolo de estimulação foi composto de duas etapas com estimulação binaural: atenção na orelha esquerda (escolha 1) e atenção na orelha direita (escolha 2). Cada etapa de estimulação tinha duração de dois minutos (equivalente a 70 janelas, considerando cada janela com 1024 pontos), com intervalo de 30 segundos entre cada. Como orientação, antes de cada tarefa, foi gerado um estímulo de dez segundos na orelha em que deveria focar a atenção (Felix et al., 2015).

2.2 Coerência Espacial e Índice de Atenção

A coerência espacial considera a Magnitude Quadrática da Coerência (MSC) e a localização espacial do eletrodo no escalpo. Essa informação permite que seja localizada a região de maior amplitude e sincronismo dos potenciais evocados (Felix et al., 2014).

O cálculo da coerência espacial é dado pelo vetor resultante obtido por meio do somatório apresentado na Equação (1). Sendo assim, esse resultado mostra a região de maior sincronismo para a frequência analisada (Felix et al., 2014; Felix et al., 2015).

$$\kappa_{espacial}(f_0) = \sum_{i=1}^{ch} \hat{\gamma}_i^2(f_0) A_i e^{j\theta_i}, \quad (1)$$

onde ch é o número de canais utilizados, $\hat{\gamma}_i^2(f_0)$ é o valor da coerência para o canal i na frequência f_0 , A_i é o módulo e θ_i é ângulo de cada eletrodo i .

Por meio da coerência espacial é possível determinar o índice de atenção, como pode ser visto na Equação (2). Esse cálculo considera a soma vetorial dos eletrodos, ponderada pela diferença na condição com atenção e sem atenção, conforme Equação (1). Para classificar a atenção, levam-se em consideração as mudanças inter-hemisféricas ocorridas durante estimulações binaurais (Felix et al., 2014; Felix et al., 2015). Essa classificação compara os valores obtidos com as frequências moduladoras da esquerda e da direita, considerando os sinais e módulos obtidos por cada índice.

$$\text{Índice de Atenção} = \text{real}(\kappa_{espacial}) \quad (2)$$

2.3 Análise de Componentes Principais (Principal Component Analysis PCA)

A Análise de Componentes Principais (Principal Component Analysis - PCA) é uma técnica utilizada em reconhecimento de padrões que tem por objetivo obter uma transformação linear ortogonal dada por (Sanei and Chambers, 2008; Moreira et al., 2014)

$$v = Wu, \quad (3)$$

onde u é o vetor de observações e as linhas de W correspondem aos autovetores normalizados da matriz de covariância dos dados.

A matriz de covariância é dada por (Sanei and Chambers, 2008; Moreira et al., 2014)

$$R = UDU^t, \quad (4)$$

onde U é a matriz de autovetores e D é a matriz diagonal na qual os elementos da diagonal correspondem aos autovalores de R . Dessa forma, a transformação linear W para PCA é dada por (Sanei and Chambers, 2008; Moreira et al., 2014)

$$W = U^t \quad (5)$$

Para a redução da dimensão pode-se adotar uma coluna de p vetores dominante na matriz. Esses serão os autovetores associados com os p maiores autovalores para a construção da matriz transformação linear W . Dessa forma, após a obtenção das componentes desejadas, o sinal poderá ser reconstruído (Sanei and Chambers, 2008).

2.4 Processamento

Para cada voluntário foi aplicada a análise de PCA nos três sinais avaliados: condição basal, atenção esquerda e atenção direita. Para cada análise foram obtidos os sinais reconstruídos que eram compostos por 19 colunas, correspondentes aos eletrodos analisados.

Após a aplicação da PCA os sinais foram processados com a coerência espacial e a classificação foi realizada conforme descrito em (Ranaudo, 2012). Os eletrodos utilizados para a classificação foram T3, P3, F3, O1, P4, O2, T4, Pz e Fz e o número máximo de janelas avaliadas foi vinte (Ranaudo, 2012; Felix et al., 2015).

3 Resultados

Na Figura 1 tem-se a média da variância explicativa das componentes principais (Principal Components - PCs) para cada um dos sinais analisados: condição basal, atenção esquerda e atenção direita. Pode-se observar que uma média de 70% dos dados são explicados pela primeira componente. Fazendo uma média dos três gráficos apresentados na Figura 1 tem-se 95% dos dados explicados por cinco componentes e 99% dos dados explicados com 11 componentes.

A Tabela 1 mostra os valores máximos obtidos para a taxa de acerto (TA), a taxa de transferência de informação (TTI) e a área abaixo da curva ROC (AUC, do inglês Area Under the Curve) na classificação dos 14 voluntários (valor médio obtido). A AUC é utilizada para verificar o desempenho do classificador. Além dessas variáveis, a tabela mostra o número de janelas necessárias para a obtenção dos valores. A classificação foi realizada com o sinal reconstruído utilizando-se de uma a 19 PCs. Com esses resultados é possível verificar que, com 11 PCs, tem-se um aumento (comparando-se com o sinal sem PCA) da TA, TTI e AUC para 92,86 %, 3,16 *bits/min* e 0,89, respectivamente. Utilizando-se números maiores de componentes não foi observado aumento nas taxas analisadas (Tabela 1).

Nas Figuras 2 e 3 tem-se a TA e TTI, respectivamente, obtidas com o sinal original e com o sinal reconstruído com 11 PCs. Nessas análises foram observadas vinte janelas do sinal. Para a maioria dos pontos, pode-se verificar que o sinal reconstruído apresentou respostas melhores, sendo o máximo citado na Tabela 1.

Na Figura 4 pode ser observada a AUC com valor máximo do sinal reconstruído com 11 PCs (0,93), utilizando-se 7 janelas, valor superior ao encontrado no sinal sem PCA (0,82 com seis janelas).




Figura 1: Variância Explicativa das componentes principais de cada sinal: condição basal, atenção no sinal da esquerda e atenção no sinal da direita (ordem do superior para o inferior).

4 Discussão

Com os resultados obtidos pode-se verificar que a aplicação da técnica de componentes principais melhora o desempenho da interface offline. Considerando os sinais sem a aplicação da PCA, tem-se as melhores respostas com máximos valores de 82,14% e 1,89 *bits/min* para a TA e TTI, respectivamente como pode ser visto em (Ranaudo, 2012).




Figura 2: Taxa de Acerto obtida com as 20 janelas iniciais do sinal, considerando o sinal original e o sinal reconstruído com 11 PCs.




Figura 3: Variação da Taxa de Transferência de Informação (*bits/min*) obtida com as 20 janelas iniciais do sinal, considerando o sinal original e o sinal reconstruído com 11 PCs.




Figura 4: Área abaixo da curva obtida a partir da classificação com as 20 janelas iniciais do sinal, considerando o sinal original e o sinal reconstruído com 11 PCs.

Os valores apresentados nos gráficos representam as taxas médias dos 14 voluntários. Com eles

Tabela 1: Comparação dos valores de taxa de acerto (TA), taxa de transferência de informação (TTI *bits/min*) e AUC (área abaixo da curva na curva ROC, do inglês Area Under the Curve). M é o número de janelas que apresentou os valores máximos e PC é o número de componentes principais (do inglês Principal Components).

	M	TA	TTI	AUC
Sinal sem PCA	6	82,14	1,89	0,82
1 PC	8	57,14	0,06	0,65
2 PCs	4	64,29	0,53	0,64
3 PC	4	67,86	0,83	0,71
4 PCs	4	75,00	1,66	0,78
5 PCs	5	75,00	1,33	0,75
6 PCs	6	89,29	2,98	0,89
7 PCs	6	85,71	2,39	0,86
8 PCs	6	85,71	2,39	0,86
9 PCs	5	85,71	2,87	0,86
10 PCs	6	85,71	2,39	0,86
11 PCs	7	92,86	3,16	0,93
12 PCs	7	92,86	3,16	0,93
13 PCs	7	85,71	2,06	0,89
14 PCs	7	89,29	2,56	0,89
15 PCs	6	85,71	2,39	0,86
16 PCs	7	85,71	2,06	0,86
17 PCs	7	85,71	2,06	0,86
18 PCs	7	82,14	1,63	0,86
19 PCs	6	78,57	1,47	0,82

pode-se notar que o máximo valor é obtido com 11,92 segundos, o que corresponde 7 janelas do sinal com $AUC = 0,93$ e utilizando-se 11 PCs (Tabela 1).

A performance da ICC desenvolvida é semelhante às encontradas na literatura, como descrito em (Kim et al., 2011), (Halder et al., 2010) e (Guo et al., 2010) que obtiveram TTIs de 2,08 *bits/min*, 2,46 *bits/min* e 3,16 *bits/min*, respectivamente. As acurácias obtidas nesses estudos também variaram entre 80 % e 90 %.

Nesse sentido, comparando-se as análises realizadas com e sem aplicação de PCA, pode-se verificar um aumento de 67 % na taxa de transferência de informação, considerando-se 11,92 s de sinal (7 janelas).

5 Conclusões

Várias técnicas têm sido aplicadas nos sinais utilizados em ICCs, tanto na extração de características, quanto na classificação dos potenciais evocados (Kim et al., 2011; Riccio et al., 2012; Moreira et al., 2014; Winkler et al., 2014). Este trabalho avaliou a utilização da análise de componentes principais (PCA) para a implementação de uma interface cérebro-computador (ICC) auditiva offline usando atenção seletiva e coerência espacial.

Os resultados permitem concluir que é possível melhorar o desempenho de uma ICC auditiva considerando uma filtragem PCA, obtendo aumento das taxas de acerto (de 82,14 % para 92,86 %) e da taxa de transferência de informação (de 1,89 *bits/min* para 3,16 *bits/min*) utilizando um tempo de sinal com uma janela a mais (7 janelas - 11,92 s de sinal).

Agradecimentos

Os autores agradecem à FAPEMIG, CAPES e CNPq pelo apoio financeiro.

Referências

- Barbosa, S., Piresa, G. and Nunesa, U. (2016). Toward a reliable gaze-independent hybrid bci combining visual and natural auditory stimuli, **261**: 47 – 61.
- Chen, S.-C., Hsu, C.-H., Kuo, H.-C. and Zaeni, I. A. E. (2014). The bci control applied to the interactive autonomous robot with the function of meal assistance, *Proceedings of the 3rd International Conference on Intelligent Technologies and Engineering Systems (ICITES2014)*, Vol. 345, Springer International Publishing, pp. 475–483.
- Chiappa, K. H. (1997). *Evoked Potentials in Clinical Medicine*.
- Dähne, S., Höhne, J., Schreuder, M. and Tangermann, M. (2011). Slow feature analysis - a tool for extraction of discriminating event-related potentials in brain-computer interfaces, *Artificial Neural Networks and Machine Learning ICANN 2011*, Vol. 6791, Springer Berlin Heidelberg, pp. 36–43.
- Felix, L. B., Neto, A. D. and de Sá, A. M. F. L. M. (2014). A spatial approach of magnitude-squared coherence applied to selective attention detection, *Journal of Neuroscience Methods* **229**: 28 – 32.
- Felix, L. B., Ranaudo, F. S., Neto, A. D. and de Sá, A. M. F. L. M. (2015). A spatial coherence-based vision-free brain-computer interface using auditory selective attention, *Medical Express (São Paulo, online)* **2(6)**.
- Guo, J., Gao, S. and Hong, B. (2010). An auditory brain-computer interface using active mental response, **18**: 230–235.
- Guo, M., Xu, G., Wang, L. and Wang, J. (2012). Research on auditory bci based on wavelet transform, *Virtual Environments Human-Computer Interfaces and Measurement Systems (VECIMS)*, IEEE International Conference.
- Halder, S., Hammer, E. M., Kleih, S. C., Bogdan, M., Rosenstiel, W., Birbaumer, N. and Kubler, A. (2013). Prediction of auditory and visual p300 brain-computer interface aptitude, **8**: e53513.
- Halder, S., Rea, M., Andreoni, R., Nijboer, F., Hammer, E. M., Birbaumer, N. and Kubler, A. (2010). An auditory oddball brain-computer interface for binary choices, **121**: 516 – 23.
- Higashi, H., Rutkowski, T. M., Washizawa, Y., Cichocki, A. and Tanaka, T. (2011). Eeg auditory steady state responses classification for the novel bci, *33rd Annual International Conference of the IEEE EMBS*.
- Hoffmann, U., Vesin, J. M. and Ebrahimi, T. (2007). Recent advances in brain-computer interfaces.
- Hong, B., Lou, B., Guo, J. and Gao, S. (2009). Adaptive active auditory brain computer interface, *31st Annual International Conference of the IEEE EMBS*.
- Kim, D. W., Hwang, H. J., Lim, J. H., Lee, Y. H., Jung, K. Y. and Im, C. H. (2011). Classification of selective attention to auditory stimuli: Toward vision-free brain computer interfacing, **197**: 180–185.
- Lopez-Gordo, M. A., Fernandez, E., Romero, S., Pelayo, F. and Prieto, A. (2012). An auditory brain-computer interface evoked by natural speech, **9**: 036013.
- Moreira, R. S., Cagy, M. and Infantesi, A. F. C. (2014). Aplicação da análise de componentes principais a potenciais antecipatórios à imagética motora em eeg, *XXIV Congresso Brasileiro de Engenharia Biomédica CBEB 2014*.
- Netto, A. D., Infantesi, A. F. C. and de Sá, A. M. L. M. (2014). A sweep operator-based algorithm for multiple coherence estimation in bci applications, *6th European Conference of the International Federation for Medical and Biological Engineering*, Vol. 45, Springer International Publishing, pp. 525–528.
- Nishikawa, N., Makino, S. and Rutkowski, T. M. (2013). Spatial auditory bci paradigm based on real and virtual sound image generation, *Signal and Information Processing Association Annual Summit and Conference (AP-SIPA)*, 2013 Asia-Pacific, IEEE, pp. 1 – 5.
- Ranaudo, F. S. (2012). Atenção seletiva auditiva usando potenciais evocados em regime permanente e coerência espacial.

- Riccio, A., Mattia, D., Simione, L., Olivetti, M. and Cincotti, F. (2012). Eye-gaze independent eeg-based brain computer interfaces for communication, **9**: 045001 – 15pp.
- Sanei, S. and Chambers, J. A. (2008). *EEG Signal Processing*.
- Väljamäe, A., Steffert, T., Holland, S., Marimon, X., Benitez, R., Mealla, S., Oliveira, A. and Jordà, S. (2013). A review of real-time eeg sonification research, *International Conference on auditory Display*.
- Winkler, I., Brandl, S., Horn, F., Waldburger, E., Allefeld, C. and Tangermann, M. (2014). Robust artifactual independent component classification for bci practitioners, **11**(3).