

Uma Abordagem Inter-indivíduo para Classificação da Atenção Seletiva Auditiva

Pedro Sergio Torres Figueiredo Silva, Leonardo Bonato Felix, Antonio Mauricio Ferreira Leite Miranda Sá, Jose Manoel Seixas

Resumo— Uma abordagem inter-indivíduo para classificação da atenção seletiva auditiva através da resposta auditiva de regime permanente é apresentada neste artigo, mostrando novos resultados encontrados pelos autores. Utilizando máquinas de vetor suporte como classificador, foram encontrados resultados similares tanto para taxa de acerto média (65,26 %) quanto para taxa de transferência de informação (2,5674 bits/min) quando comparados aos valores obtidos anteriormente, também notando que os melhores resultados foram obtidos com configurações de parâmetros. Assim, é apontado que ainda são necessários futuros estudos para definição do quanto tal método pode ser melhorado.

Palavras-Chave — Atenção Seletiva Auditiva, Resposta Auditiva de Regime Permanente, Interface Cérebro-Computador, Máquina de Vetores Suporte.

Abstract— An intersubject approach for classification of the auditory selective attention through the auditory steady-state response is presented in this paper, showing new results found by the authors. Using support vector machines as the classifier, it were found similar results for average hit rate (65.26 %) as well as for the information transfer rate (2.5674 bits/min) when compared to the values previously obtained, also noticing that the best results were obtained with the same parameter setting. Thus, it is pointed out that future studies are still necessary to define how much the presented method can be improved.

Keywords — Auditory Selective Attention, Auditory Steady-State Response, Brain-Computer Interfaces, Support Vector Machines.

I. INTRODUÇÃO

A atenção seletiva auditiva (ASA) pode ser definida como a habilidade de focar em um estímulo sonoro de interesse enquanto ignoram-se outros estímulos presentes no mesmo ambiente. Um exemplo clássico da ASA é conhecido como *Cocktail Party Effect*, ilustrando o caso de uma pessoa que consegue manter o foco da sua atenção na fala de um interlocutor mesmo em um ambiente ruidoso, como uma festa [1]. Algumas aplicações da ASA encontradas na literatura incluem estudos envolvendo condições como o transtorno do déficit de atenção com hiperatividade [2], depressão [3], doença de Alzheimer [4] e autismo [5], sendo inclusive discutidas possibilidades de auxílio de diagnóstico a partir de características atípicas da ASA. Outra aplicação bastante explorada é a classificação do efeito para uso em interfaces cérebro-computador (*Brain-Computer Interface* - BCI), sendo estes sistemas desenvolvidos para agir como meios alternativos para envio de comandos para o ambiente sem passar pelos caminhos naturais do cérebro (nervos e músculos) [6].

Um potencial evocado auditivo (PEA) pode ser definido como uma atividade bioelétrica desencadeada por alguma estimulação externa, sendo registrada no nervo, músculo, receptor sensorial ou área do sistema nervoso central [7]. A resposta auditiva de regime permanente (*Auditory Steady-State Response* - ASSR) caracteriza-se como um PEA constituído a partir de respostas a estímulos individuais apresentados a uma taxa suficientemente alta, de modo a ocorrer a sobreposição dessas respostas [8]. Tais respostas também podem ser obtidas através da estimulação sonora por tons puros modulados em amplitude (AM) [9], gerando uma ASSR com a característica de incremento da energia na frequência de modulação, quando observado o espectro de potência do sinal [10]. Estudos envolvendo o efeito da ASA sobre a ASSR apresentam resultados contraditórios, como pode ser visto em [6], [11], [12] e [13]. No entanto, a maioria desses trabalhos parece convergir para um incremento da amplitude da ASSR durante o período de atenção, como apontado em [14].

A aplicação do efeito da ASA sobre a ASSR como um paradigma para BCIs foi abordada por [8], [15] e [16], obtendo resultados pertinentes. Um modelo para a classificação da ASA utilizando a ASSR e o PEA de curta latência P300 foi proposto por [17], mostrando como essa combinação pode elevar o desempenho da classificação. Em um trabalho mais recente, [18] alcançou níveis de taxa de acerto da classificação de 91,67 % com taxa de transferência da informação (ITR) associada de 6,74 bits/min, sendo esses ótimos valores para essas medidas de desempenho.

No presente trabalho, volta-se a explorar uma abordagem inter-indivíduo para a classificação da atenção seletiva auditiva, expandindo as análises realizadas em [19]. Nesse tipo de abordagem, os dados são coletados de vários voluntários, sendo o classificador treinado para identificar padrões mais gerais e que sejam válidos para um grande número de pessoas. Apesar da desvantagem de lidar com uma grande variabilidade presente em dados de múltiplas pessoas [20, 21], esta abordagem apresenta vantagens interessantes, como a aplicação em um sistema que funcione com novos usuários sem a necessidade de coleta de dados dos mesmos para treinamento. Assim, buscando uma melhora de desempenho do método já desenvolvido, é realizada uma análise por meio da silhueta média dos clusters para identificação de possíveis subclusters no banco de dados, o que pode prejudicar o desempenho da classificação. Além disso, também são mostrados resultados obtidos com o uso de máquinas de vetor suporte (*Support Vector Machines* - SVM) [22] para a classificação, comparando o desempenho desses

Pedro Sérgio Tôrres Figueiredo Silva, Laboratório de Processamento de Sinais e Inteligência Computacional, Universidade Federal do Rio de Janeiro, e-mail: pedrosergiot@ufrj.br; Leonardo Bonato Félix, Núcleo Interdisciplinar de Análise de Sinais, Universidade Federal de Viçosa; Antonio Mauricio Ferreira Leite Miranda de Sá, Programa de Engenharia Biomédica, Universidade Federal do Rio de Janeiro; José Manoel Seixas, Laboratório de Processamento de Sinais, Poli/COPPE, Universidade Federal do Rio de Janeiro;

classificadores com o das redes neurais artificiais (*Artificial Neural Networks* - ANN) utilizadas em [19].

II. MATERIAIS E MÉTODOS

A. Dados Utilizados

Neste estudo, foram utilizados dados obtidos a partir de eletroencefalograma (EEG) de 49 adultos sem sinais de perdas auditivas ou patologias neurológicas. Cada voluntário pode participar do procedimento de coleta até quatro vezes, considerando um intervalo mínimo de uma semana entre as repetições, para evitar efeitos de treinamento [23]. O protocolo de coletas utilizado foi aprovado pelo comitê de ética local (CEP/UFV: 1.637.358).

Os sinais de EEG utilizados foram coletados durante a realização de uma tarefa de atenção auditiva por parte dos voluntários, usando estimulação por dois tons AM distintos para evocar ASSR durante a tarefa. Foram utilizadas frequências de modulação de 32 Hz (orelha esquerda) e 38 Hz (orelha direita), portadoras de 500 Hz e 2000 Hz, respectivamente. Os sinais foram gerados digitalmente com uma frequência de amostragem de 44100 Hz. A amplitude dos estímulos gerados foi de 75 dB SPL e a profundidade de modulação utilizada foi de 100 %. Importante destacar que ambos os sinais utilizados como estímulo tiveram uma pequena correção na frequência de modulação, seguindo o método de [10], de modo a ter um número inteiro de ciclos do sinal dentro de janelas de 1024 pontos, evitando assim o espalhamento espectral (tal medida foi realizada para permitir o uso dos dados em outros estudos envolvendo análise no domínio da frequência).

A estimulação consistiu na apresentação simultânea dos estímulos ao voluntário (estimulação dicótica) seguindo três etapas. Na primeira etapa, com duração de 30 segundos, os estímulos eram apresentados simultaneamente ao voluntário, que era instruído a tentar ignorar ambos. Após isso, o voluntário foi instruído a focar a atenção em apenas um dos estímulos na segunda etapa, que teve duração de 10 segundos. Na última etapa, também com duração de 10 segundos, o voluntário foi instruído a focar sua atenção no estímulo ignorado na etapa anterior. O intervalo entre cada etapa foi variado entre 5 a 20 segundos, sendo a instrução dada ao voluntário na forma de uma breve estimulação individual (1,5 segundos) apenas na orelha em que ele deveria focar a atenção. O protocolo é ilustrado na Figura 1.

A aquisição dos dados foi realizada com o amplificador de sinais biológicos BrainNet BNT-36 (EMSA, Brasil) de 36 canais e com filtro passa-faixa em 0,1 Hz - 100 Hz. A frequência de amostragem utilizada foi de 600 Hz e foi também utilizado um filtro notch em 60 Hz, para evitar interferências provenientes da rede elétrica. Os EEG foram registrados usando 19 eletrodos Ag-AgCl (Cz, C3, C4, T3, T4, T5, T6, Pz, P3, P4, O1, O2, Fz, F3, F4, F7, F8, Fp1 e Fp2), dispostos de acordo com o sistema internacional 10-20 e com referência no eletrodo Oz, sendo o terra posicionado na testa do voluntário. O primeiro segundo de cada exame foi descartado em uma tentativa de

eliminar o período transitório inerente à mudança do estado de atenção de uma pessoa, sendo também aplicado o mesmo método de rejeição de artefatos usado em [18]. No total, foram realizadas 144 coletas, totalizando 288 amostras para o banco de dados. Cada amostra foi dividida em janelas de 64 pontos, sendo o número de janelas utilizadas um dos parâmetros para os seguintes passos da análise.

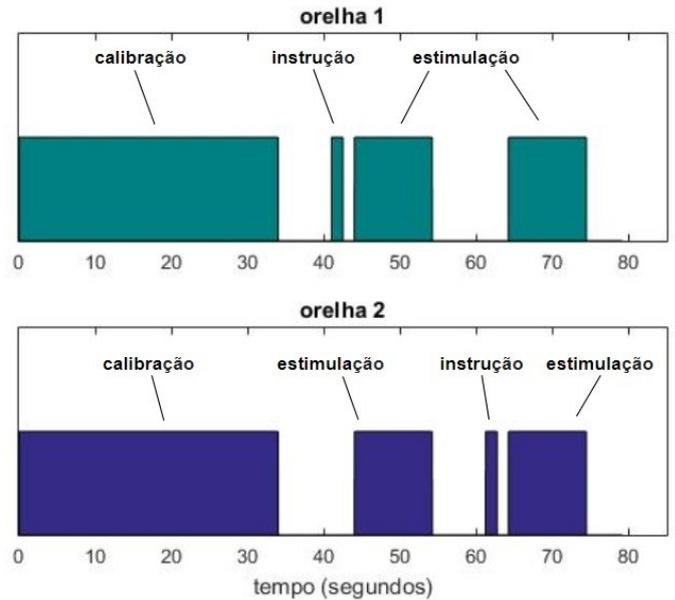


Fig. 1. Protocolo de estimulação utilizado.

B. Extração de Características

O primeiro passo da extração de características foi baseado na análise de componentes principais (PCA), sendo os dados projetados em um novo subespaço vetorial de variáveis não-correlacionadas [24]. Neste subespaço, os componentes de menor energia foram descartados, reconstruindo o sinal com as componentes restantes. Tal passo foi realizado no intuito de tentar diminuir o nível de ruído contido no sinal obtido pelo EEG. O número de componentes utilizadas para a reconstrução do sinal no espaço original foi variado de 1 até 18, considerando os 19 eletrodos disponíveis.

Como o custo computacional para testar todas as combinações entre os 19 eletrodos disponíveis seria muito alto, foi selecionado um conjunto contendo os eletrodos Cz, F7, F8, T3 e T4, sendo a localização deste conjunto apontada na Figura 2. Tais eletrodos foram selecionados por frequentemente serem utilizados em outros estudos similares [8, 17]. Todas as combinações possíveis entre esses eletrodos foram avaliadas.

Assumindo que o foco da atenção em um tom AM resulta em uma ASSR com aumento de amplitude relativa à frequência moduladora [15, 26, 27], foram usados, como características, os valores de energia para as frequências de modulação dos sinais dos eletrodos usados. Para tal, o sinal de cada eletrodo foi filtrado individualmente por dois filtros passa-faixa (filtros do tipo Butterworth de 4º ordem centrados nas frequências de modulação e com banda de 0,2 Hz), gerando dois sinais

resultantes por eletrodo, um para cada frequência de modulação. Foi então calculado o valor de energia para cada sinal resultante correspondente a um eletrodo usando o teorema de Parseval [28], sendo esses valores de energia agrupados para formar o sinal que alimenta o sistema de classificação.

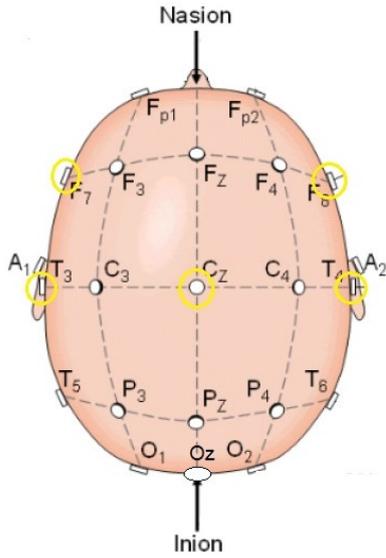


Fig. 2. Conjunto de eletrodos utilizados na análise. Figura modificada de [25].

C. Normalização dos dados

Após a etapa de extração de características, seguiu-se uma etapa de normalização de dados, sendo utilizada para reduzir o efeito da alta variabilidade presente nos dados coletados de vários voluntários diferentes.

A normalização dos dados foi feita em duas etapas. Primeiramente, os valores de energia das amostras de atenção à esquerda e à direita para uma mesma coleta foram divididos pelo maior valor dentre eles, obtendo assim valores na faixa entre 0 e 1.

A segunda etapa teve como objetivo de gerar valores dentro da faixa de -1 a 1, por conta da função de ativação tangente hiperbólica usada na camada oculta da ANN. Essa normalização foi feita pela seguinte equação, apresentada em [29]:

$$p_n = 2(p - p_{min}) / (p_{max} - p_{min}) - 1, \quad (1)$$

onde p_{min} e p_{max} são os vetores contendo os valores mínimos e máximos, respectivamente, de cada variável (colunas) dos dados contidos na matriz p .

D. Identificação de Clusters

Antes da aplicação dos métodos de classificação, foi feita uma clusterização não-supervisionada para identificação de possíveis subclusters, que podem reduzir o desempenho da classificação. Como os dados descrevem apenas dois tipos de condição (atenção ao som na orelha esquerda e atenção ao som

na orelha direita), espera-se que a melhor clusterização seja a obtida com apenas dois clusters.

Para a clusterização, foram usados os dados antes da aplicação da PCA, sendo aplicadas as outras etapas (filtragem, cálculo dos valores de energia e normalização) para extração de características. A clusterização foi feita utilizando o método *k-means*, sendo o número de clusters variado de 2 até 6. A silhueta média de cluster [30] foi utilizada como medida de desempenho da clusterização. Valores de silhueta média próximos de 1 indicam uma boa clusterização (alta similaridade entre elementos presentes em cada cluster).

E. Classificação dos Dados

Complementando as análises apresentadas em [19], foi utilizado como classificador a SVM. A função de base radial [22] foi usada como *kernel* desse classificador, sendo os valores dos seus hiperparâmetros selecionados através de otimização bayesiana. Os resultados da SVM foram avaliados utilizando a validação cruzada *k-fold* [31], com $k = 10$.

Assim como em [19], as medidas de desempenho adotadas foram a taxa de acerto e a taxa de transferência de informação (*Information Transfer Rate* - ITR). A taxa de acerto é dada pela proporção de exemplares do conjunto de teste (dados são divididos em conjuntos para treino do modelo e teste do mesmo) corretamente classificados em cada iteração da validação *k-fold*, sendo tomada a média das iterações. Já a ITR leva em conta tanto a taxa de acerto quanto a velocidade da classificação [32], sendo dada pela seguinte equação:

$$ITR = s[\log_2 N + H \log_2 H + (1 - H) \log_2 (\frac{1 - H}{N - 1})], \quad (2)$$

onde N é o número de comandos possíveis ($N = 2$ para o caso de classificação binária), H é a taxa de acerto e s é o número de comandos executados por minuto, sendo este último dependente do tamanho do sinal utilizado (número de janelas) para a detecção do comando.

III. RESULTADOS

A Figura 3 apresenta o resultado da clusterização dos dados, mostrando os valores da largura média da silhueta em função do número de clusters utilizados. Pode-se notar o decaimento da silhueta média com o aumento do número de clusters, implicando que a clusterização com apenas dois clusters é a melhor opção (o que condiz com a natureza dos dados). No entanto, o valor máximo da silhueta média é bem baixo, indicando uma fraca clusterização. Levando-se em conta os dados coletados na abordagem inter-indivíduo e sua grande variabilidade [33], tal resultado aponta a dificuldade da tarefa de classificação.

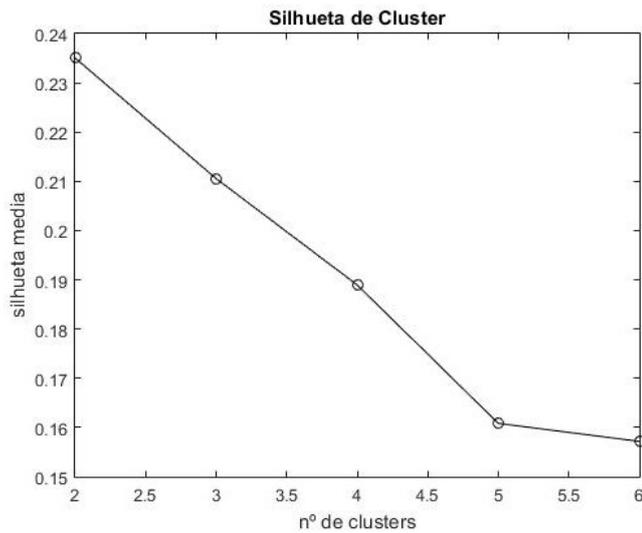


Fig. 3. Silhueta média em função do número de clusters utilizados na clusterização.

A Tabela I mostra a comparação dos melhores resultados, selecionados em termos da taxa de acerto média da validação cruzada, obtidos com a SVM e com o método descrito em [19], utilizando redes neurais artificiais. A validação cruzada *k-fold* repetida utilizada em [19] tem um alto custo computacional e foi optado por não utilizá-la neste trabalho, usando a validação *k-fold* convencional para estimar a performance de ambos os classificadores, gerando uma pequena diferença entre os valores das medidas de desempenho encontradas no presente trabalho e as apresentadas em [19]. Nota-se que os valores médios da taxa de acerto são bem similares para ambos os classificadores, refletindo também valores próximos da ITR média. O teste dos postos sinalizados de Wilcoxon [34] foi utilizado nos resultados obtidos pela validação cruzada *k-fold*, não apontando diferença significativa entre os classificadores para um nível de significância de 5% ($p = 0,7656$). Interessante notar, que o melhor desempenho para ambos os classificadores foi encontrado com combinações de parâmetros bem parecidas, diferindo apenas nos eletrodos usados. Isso pode sugerir um número ótimo para esses parâmetros, embora estudos com outros classificadores sejam necessários para ter tal definição.

Mesmo com a taxa de acerto ainda apresentando nível bem abaixo de trabalhos recentes, como [17] e [18], cabe ressaltar novamente a dificuldade da tarefa de classificação de dados coletados de múltiplos indivíduos. Apesar dessa abordagem aparentar ter grande desvantagem quando comparada com abordagens individualizadas, também existem algumas vantagens importantes, como não precisar de longas sessões de calibração do sistema para novos usuários [33] e a possibilidade de se estimar um efeito global relativo à atenção seletiva, contribuindo assim para o entendimento desse mecanismo.

TABELA I. COMPARAÇÃO DE RESULTADOS OBTIDOS PELA VALIDAÇÃO CRUZADA ENTRES OS CLASSIFICADORES UTILIZADOS.

	SVM	Melhor resultado obtido com método apresentado em [19]
Taxa de acerto média (%)	65,26	64,31
Maior taxa de acerto (%)	78,57	85,71
Menor taxa de acerto (%)	53,57	50,00
ITR média (bits/min)	2,5674	2,2525
Eletrodos utilizados	Cz, F7, F8, T4	Cz, T3 e T4
Nº de PCs usadas	2	2
Nº de janelas de sinal usadas	4	4

IV. CONCLUSÃO

Um método inter-indivíduo para classificação da ASA através do seu efeito na ASSR foi apresentado neste trabalho, sendo feitas novas análises e comparando-as com o desempenho geral obtido em um trabalho anterior. A análise por clusterização demonstra a dificuldade de classificação dos dados obtidos por essa abordagem, o que é esperado dada a grande variabilidade intrínseca a dados de EEG provenientes de vários voluntários. Também foi realizada a classificação por SVM, obtendo valores para as medidas de desempenho (taxa de acerto média de 65,26% com ITR de 2,5674 bits/min) similares aos encontrados no estudo anterior. Assim, ainda são necessários estudos futuros para definir a extensão do quanto o método inter-indivíduo pode ser melhorado tendo em vista sua aplicação em um sistema BCI.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código do Financiamento 001. Adicionalmente, os autores agradecem CNPq e FAPERJ pelo apoio ao trabalho desenvolvido.

REFERENCES

- [1] A. W. Bronkhorst, "The cocktail party phenomenon: a review of research on speech intelligibility and multiple-talker conditions", *Acustica*, v. 86, pp. 117-128, 2000.

- [2] H. Gomes, M. Duff, M. Ramos, S. Molholm, J. J. Foxe, “Auditory selective attention and processing in children with attention-deficit/hyperactivity disorder”, *Clinical neurophysiology*, v. 123, n. 2, pp. 293-302, 2012.
- [3] E. Greimel, M. Trinkl, J. Bartling, S. Bakos, N. Grossheinrich, G. Schulte-Korne, “Auditory selective attention in adolescents with major depression: an event-related study”, *Journal of affective disorders*, v. 172, pp. 445-452, 2015.
- [4] C. D. Papadaniil, V. E. Kosmidou, A. Tsolaki, M. Tsolaki, I. Y. Kompatsiaris, L. J. Hadjileontiadis, “Cognitive MMN and P300 in mild cognitive impairment and Alzheimer’s disease: a high density EEG-3D vector field tomography approach”, *Brain research*, v. 1648, pp. 425-533, 2016.
- [5] J. Tillmann, J. Swettenham, “Contrasting the effects of task difficult and perceptual load on auditory detection sensitivity in individuals with autism”, *Journal of autism and developmental disorders*, v. 49, n. 2, pp. 762-772, 2018.
- [6] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, T. M. Vaughan, “Brain-computer interfaces for communication and control”, *Clinical Neurophysiology*, v. 115, pp. 767-791, 2002.
- [7] H. K. Chiappa, *Evoked potentials in clinical medicine*, Lippincott Williams & Wilkins, 1997.
- [8] L. B. Felix, F. S. Ranaudo, A. D. Netto, A. M. F. L. A. Miranda de Sá, “A spatial approach of magnitude-squared coherence applied to selective attention detection”, *Journal of Neuroscience Methods*, v. 229, pp. 28-32, 2014.
- [9] S. Kuwada, R. Batra, V. L. Mahere, “Scalp potentials of normal and hearing-impaired subjects in response to sinusoidally amplitude-modulated tones”, *Hearing research*, v. 21, n. 2, pp. 179-192, 1986.
- [10] L. B. Felix, J. E. Moraes, A. M. F. L. A. Miranda de Sá, H. C. Yehia, M. F. D. Moraes, “Avoiding spectral leakage in objective detection of auditory steady-state evoked response in the inferior colliculus of rat using coherence”, *Journal of Neuroscience Methods*, v. 144, n. 2, pp. 249-255, 2005.
- [11] R. D. Linden, T. W. Picton, G. Hamel, K. B. Campbell, “Human auditory steady-state evoked potentials during selective attention”, *Electroencephalography and Clinical Neurophysiology*, v. 66, pp. 145-159, 1987.
- [12] H. T. Tiitinen, J. Sinkkonen, K. Reinikainen, “Selective attention enhances the auditory 40 Hz transient response in humans”, *Nature*, v. 6432, n. 364, pp. 59-60, 1993.
- [13] B. Ross, T. W. Picton, A. T. Herdman, “The effect of attention on auditory steady-state response”, *Neurology and Clinical Neurophysiology*, v. 22, pp. 1-4, 2004.
- [14] Y. Mahajan, C. Davis, J. Kim, “Attentional modulation of auditory steady-state responses”, *PLoS ONE*, v. 9, n. 10, 2014.
- [15] M. A. Lopez, H. Pomarez, F. Pelayo, J. Urquiza, J. Perez, “Evidences of cognitive effects over auditory steady-state response by means of artificial neural networks and its use in brain-computer interfaces”, *Neurocomputing*, v. 75, pp. 3617-3623, 2009.
- [16] D. W. Kim, H. J. Hwang, J. H. Lim, Y. H. Lee, K. Y. Jung, C. H. Im, “Classification of selective attention to auditory stimuli: toward vision-free brain-computer interfacing”, *Neuroscience Methods*, v. 197, n. 1, pp. 180-185, 2011.
- [17] N. Kaongoen e S. Jo, “A novel hybrid auditory BCI paradigm combining ASSR and P300”, *Journal of Neuroscience Methods*, v. 279, pp. 44-51, 2017.
- [18] A. P. Souza, Q. B. Soares, L. B. Felix, E. M. A. M. Mendes, “Classification of auditory selective attention using spatial coherence and modular attention index”, *Computer Methods and Programs in Biomedicine*, v. 166, pp. 107-113, 2018.
- [19] P. S. T. F. Silva, L. B. Felix, “Detection of auditory selective attention using artificial neural networks: an intersubject analysis”, *XXVI Brazilian Congress on Biomedical Engineering*, 2018.
- [20] S. Lu, C. Guan, H. Zhang, “Unsupervised brain computer interface based on inter-subject information”, *30th Annual International IEEE Engineering in Medicine and Biology Society*, pp. 638-641, 2008.
- [21] J. Stastny, P. Sovka, M. Kostilek, “Overcoming inter-subject variability in BCI using EEG-based identification”, *Radioengineering*, v. 23, n. 1, pp. 266-273, 2014.
- [22] C. M. Bishop, *Pattern Recognition and Machine Learning*, Springer, 2006.
- [23] A. P. Souza, L. B. Felix, A. M. F. L. A. Miranda de Sá, E. M. A. M. Mendes, “Vision-free brain-computer interface using auditory selective attention: evaluation of training effect”, *XIV Mediterranean Conference on Medical and Biological Engineering and Computing*, pp. 196-199, 2016.
- [24] D. C. Lay, S. R. Lay, J. J. McDonald, *Linear algebra and its applications*, 5th edition. Pearson, 2016.
- [25] F. Sharbrough, G. E. Charian, R. P. Lesser, H. Luders, M. Nuwer, T. W. Picton, “American electroencephalographic society guidelines for standard 57 electrode position nomenclature”, *Journal of Clinical Neurophysiology*, v. 8, n. 2, pp. 200-202, 1991.
- [26] N. Muller, W. Schlee, T. Hartmann, I. Lorenz, N. Weisz, “Top-down modulation of the auditory steady-state response in a task-switch paradigm”, *Frontiers in human neuroscience*, v. 3, pp. 1, 2009.
- [27] P. E. Gander, D. J. Bosnyak, R. Wolek, L. E. Roberts, “Modulation of 40-Hz auditory steady-state response by attention during acoustic training”, *International congress series*, v. 1300, pp. 37-40, 2007.
- [28] B. P. Lathi, *Sinais e Sistemas Lineares*, 2. ed., Bookman, 2007.
- [29] M. T. Hagan, H. B. Demuth, M. H. Beale, O. De Jesus, *Neural Networks Design*, 2nd edition, Martin Hagan, 2014.
- [30] P. J. Rouseeuw, “Silhouettes: a graphical aid to the interpretation and validation of cluster analysis”, *Journal of Computational and Applied Mathematics*, v. 20, n. 1, pp. 53-65, 1987.
- [31] I. N. Da Silva, D. Spatti, R. Flauzino, *Redes Neurais Artificiais para engenharia e ciências aplicadas: curso prático*, Artliber Editora Ltda, 2010.
- [32] D. J. McFarland, W. A. Sarnacki, J. R. Wolpaw, “Brain-computer interface (BCI) operation: optimizing information transfer rates”, *Biology Psychology*, v. 63, n.3, pp. 237-251, 2003.
- [33] S. Saha, K. I. Ahmed, R. Mostafa, A. H. Khandoker, L. Hadjileontiadis, “Enhanced inter-subject brain-computer interface with associative sensorimotor oscillations”, *Healthcare technology letters*, v. 4, n. 1, pp. 39-43, 2017.
- [34] F. Wilcoxon, “Individual comparisons by ranking methods”, *Biometrics Bulletin*, v. 1, n. 6, pp. 80-83, 1945.