

A Fast and Accurate SSVEP Brain Machine Interface Using Dry Electrodes and High Frequency Stimuli by Employing Ensemble Learning

A. Silva, G. Cruz, and C. Pinheiro

Abstract—This paper presents an original approach to the processing and classification of visual evoked potentials signals (SSVEP). It introduces an ensemble-learning model that combines canonical correlation analysis with methods based on power spectral density. The stimuli used was built using LEDs and ranged from 7.04 Hz up to 38.46 Hz. The data was collect using ADS1299 and three dry electrodes. The tests were performed for different light intensities and different distances between the LEDs. In total, 22 participants were recruited, and the mean accuracy was 99.1 ± 2.27 % with a decision time of 1 second. To the best of our knowledge, these results surpass what was previously published in others works that used high frequency stimuli in SSVEP-BCI, i.e., a mean accuracy of approximately 90%, with decision time of 5 seconds.

Index Terms—Canonical correlation analysis, Brain-computer, EEG, Visual evoked potentials, SSVEPC.

I. INTRODUÇÃO

PESSOAS com limitações severas de movimento dependem de interfaces que necessitam de pouca movimentação e relativamente alta taxa de acerto. Diversas enfermidades podem levar a um quadro de limitação severa de movimento, tais como esclerose lateral amiotrófica, síndrome do encarceramento e acidente vascular cerebral.

Para lidar com essas situações, dentre as técnicas conhecidas, as que envolvem Potencial Evocado Visual (PEV) têm apresentado melhores perspectivas por terem apresentado bons resultados e demandarem menor tempo de treinamento dos indivíduos para sua utilização [1], [2]. PEV estáveis (Steady State Visual Evoked Potential - SSVEPs) são potenciais evocados na região occipital do córtex cerebral, decorrentes da excitação da retina em determinadas frequências.

A excitação da retina pode ser realizada utilizando uma imagem oscilando entre as cores brancas e pretas, por meio de um monitor de um computador.

No entanto, a frequência do monitor deve ser divisível pela frequência do estímulo gerado, além disto, os sistemas operacionais atuais não foram desenvolvidos para aplicações de tempo real, dificultando a geração de estímulos precisos. Uma alternativa é a utilização de *Light-Emitting Diode* (LEDs), que não apresentam os problemas mencionados. Sinais SSVEP se mostraram bem-sucedidos em diversos sistemas cérebro-computador. Além disso, sinais SSVEP são detectados em conjuntos populacionais grandes [3]. Todavia, uma crítica comumente realizada a tais sistemas é a fadiga visual causada pelo estímulo, além de muitos participantes descreverem os estímulos como "irritantes" [4]–[6].

Uma forma de reduzir significativamente essa reclamação foi a adoção da utilização de frequências de estímulos acima de 25 Hz e a utilização da cor de estímulo branca, azul ou verde [7]. Em contrapartida, estímulos em frequências acima da região alpha (7.5 - 12.5 Hz) são consideravelmente mais difíceis de serem detectados em períodos curtos de tempo [6], [8], [9].

Para que uma interface humano-computador seja factível, somente o conforto não é suficiente, ela deve também possuir uma alta taxa de acertos, e ser capaz de enviar diversos comandos por minuto. Buscando-se atender esse objetivo, a Análise da Correlação Canônica (CCA) foi empregada pela primeira vez por [10], para detecção de sinais SSVEP. Diferentemente da abordagem tradicional que utiliza a Densidade Espectral de Potência, a CCA é capaz de detectar atividades SSVEP em janelas de tempo muito pequenas, menores do que quatro segundos [10], [11].

Uma abordagem recentemente publicada mostrou resultados um pouco melhores para frequências acima da região alpha, em comparação com a CCA tradicional, contudo com resultados piores para frequências baixas [12]. Esta técnica, chamada de *differential CCA*, obteve uma taxa de acertos de $67,85\% \pm 13,49\%$, se mostrando superior o CCA tradicional ($61,52\% \pm 14,77\%$), para frequências altas [12].

No ano de 2015, um estudo realizado em 12 participantes [13], utilizou LEDs em frequências na faixa de 30 a 70 Hz e obteve uma taxa de acerto média de 90%. O trabalho concluiu que a utilização de frequências altas diminui consideravelmente a fadiga visual.

Em 2017, apresentou-se uma implementação por meio de Redes Neurais Convolucionais [14], obtendo 99,28% de taxa de acertos, em 4 segundos de dados. Os testes foram realizados com 7 indivíduos e utilizou estímulos com LED em frequência entre 9-17 Hz e 8 canais de Eletroencefalograma (EEG).

A. D. D. Silva, Universidade Federal de Goiás, Goiânia, Goiás, Brasil, andreidamian@gmail.com.

C. G. Pinheiro, Junior, Universidade Federal de Goiás, Goiânia, Goiás, Brasil, cgalvao@emc.ufg.br.

G. D. Cruz, Junior, Universidade Federal de Goiás, Goiânia, Goiás, Brasil, gcruz@emc.ufg.br.

Corresponding author: A. D. D. Silva.

Contrastando com a CCA tradicional, existem métodos que empregam uma etapa de treinamento para se obter um ótimo sinal de referência [15]–[17]. A crítica a esses métodos é que tendem ao sobre-ajuste (*overfitting*), pois quando empregados em longos períodos, ou até em sessões diferentes não apresentam um desempenho tão promissor. Além disto, se a etapa de treinamento não for bem realizada, o resultado pode ficar inferior a CCA tradicional [18].

O objetivo deste trabalho é contribuir para o desenvolvimento de interfaces SSVEP práticas e acessíveis. Por essa razão, empregou-se poucos eletrodos a seco, um equipamento de coleta de sinal de baixo custo, construiu-se estimuladores SSVEP baseados em LEDs, além da utilização de frequências acima de 25 Hz. Adicionalmente, verificou-se o impacto de valores de luminosidade e distância entre os estímulos.

Buscando-se atingir estes objetivos, foram empregadas etapas de filtragem do sinal EEG e posteriormente a extração de características do sinal e classificação. O ponto de maior contribuição deste trabalho ocorre na extração das características, onde são apresentadas novas características para classificação de sinais SSVEP. A Figura 1 resume o fluxo da informação no sistema elaborado neste estudo. Explicar a Figura 1.




Fig. 1. Diagrama geral da metodologia utilizada para classificação do sinal SSVEP.

II. OBTENÇÃO DO SINAL SSVEP

Para aquisição do sinal EEG, foi utilizado a placa ADS1299eeg-fe (*Texas Instruments*), conectada a um *notebook* através de cabo USB. Foi adotado um circuito utilizando ADS1299 devido ao seu baixo consumo de energia, a pequena quantidade de componentes externos necessários e seu tamanho compacto, facilitando atendermos nosso objetivo de desenvolver um aparelho portátil. A placa de captura foi alimentada com baterias. A frequência de amostragem utilizada foi de 250 Hz. O *notebook* foi mantido desconectado da rede de energia elétrica. Foram utilizados somente três eletrodos secos TDE-200, que podem ser vistos na Figura 2, costurados em uma faixa de tecido. A disposição dos eletrodos foi

aproximadamente em O1, O2 e Oz (Sistema de posicionamento 10-20 [19]). O *software* utilizado foi desenvolvido em ambiente LABView. A análise dos dados foi realizada em ambiente MATLAB.

III. CONSTRUÇÃO DO ESTIMULADOR SSVEP

Para construção de um estimulador, optou-se por utilizar LEDs, devido a possibilidade de realizar estímulos SSVEP acima de 25 Hz de forma confiável, e que não exigisse um *hardware* complexo [20].



Fig. 2. Eletrodos a seco TDE-200, fabricados pela *Florida Research Instruments*.

Foram utilizados 6 LEDs de alto brilho, com ângulo de 30° de abertura, da cor branca, pois apresentam forte resposta SSVEP e são considerados confortáveis [6]. Os LEDs foram colocados em superfícies plásticas, dispostos de duas formas diferentes, com distâncias entre si de 5 cm e 1 cm, conforme os diagramas da Figura 3.




Fig. 3. Representação dos dois aparatos plásticos contendo os LEDs.

As frequências utilizadas foram 7.04, 10, 15.15, 25, 35.71 e 38.46 Hz. Os valores foram escolhidos de forma a evitar que os as frequências coincidisse com as harmônicas de outros estímulos. Todavia, devido a imprecisões do circuito, a frequência de estímulo gerada é diferente da calculada. Por exemplo, o valor desejado de estímulo era 7Hz, mas o valor medido com osciloscópio no LED foi de 7.04Hz. Um dos objetivos era avaliar a possibilidade de detectar atividades SSVEP acima de 25 Hz, visando aumentar o conforto dos usuários [6], [8].

Utilizou-se uma placa Arduino UNO para realizar a programação das frequências dos LEDs. A frequência foi conferida com auxílio de um osciloscópio (TDS 1002C-EDU). O *duty cycle* foi de 50%, ou seja, para cada ciclo o LED fica ativo metade do tempo. O valor de corrente elétrica dos LEDs foi alterado ao longo do experimento utilizando um potenciômetro (B100K).

Maiores detalhes sobre os valores de corrente elétrica e consequentemente de luminância dos LEDs, serão explicados na sessão VIII e IX.

IV. FILTRAGEM DO SINAL EEG

Inicialmente foram excluídos todos os segmentos de sinais onde o valor medido fosse contínuo em 0 V, decorrente de uma possível saturação do sinal. Esse tipo de situação pode ocorrer por mal contato do eletrodo com a pele, movimentos bruscos do participante ou ganho excessivo do amplificador. O critério para determinar o que pode ser desconsiderado foi por meio de inspeção visual dos sinais. Esse processo foi necessário para remover alguns segmentos obtidos nos dois primeiros experimentos, devido ao ganho excessivo (24x) utilizado no ADS1299. Nos demais participantes na coleta de dados foi utilizado um ganho de 2x no ADS1299.

Para remoção das interferências da linha de energia elétrica presentes na coleta do sinal EEG, foram aplicados filtros FIR *notch* digitais em 60 e 120 Hz, com fator Q de 10. Foram empregados filtros *notch*, pois apesar da transmissão dos dados serem sem fio e o equipamento ser alimentado por bateria, os usuários estão próximos de outros equipamentos ligados a rede elétrica e a presença de ruídos em 60Hz e suas harmônicas são detectados.

Empregou-se a Análise das Componentes Independentes (ICA), utilizando-se o algoritmo *fastICA* [21]. A ICA pode ser vista como uma forma de separar sinais que sejam decorrelacionados e independentes entre si. Idealmente, deseja-se separar a atividade SSVEP das atividades espontâneas do EEG e dos demais ruídos presentes no sinal [22]. Sua eficácia para processamento de sinais EEG já foi demonstrada em trabalhos anteriores [23]–[25].

V. ANÁLISE DA CORRELAÇÃO CANÔNICA (ACC)

A Análise da Correção Canônica (ACC) é uma técnica que busca encontrar a correlação entre dois conjuntos de variáveis. Seu diferencial é aplicar transformações lineares nos conjuntos de variáveis, de tal forma a tentar maximizar sua correlação. Atualmente é a técnica mais utilizada para detecção de atividades SSVEP em curto espaço de tempo [11]. A detecção de atividade SSVEP através da CCA, consiste em gerar um conjunto de sinais de referências na mesma frequência dos estímulos utilizados, podendo incorporar suas harmônicas.

Formalmente, define-se a CCA da seguinte forma: Considere dois conjuntos de variáveis aleatórias $X \in \mathbb{R}^{1 \times J}$ e $Y \in \mathbb{R}^{1 \times J}$ e a combinação linear $\tilde{x} = w^T X$ e $\tilde{y} = v^T Y$, a CCA tenta encontrar um par de combinações lineares $w \in \mathbb{R}^{1 \times J}$ e $v \in \mathbb{R}^{1 \times J}$ que maximize a correlação entre \tilde{x} e \tilde{y} através da resolução de (1), onde o máximo ρ corresponde a correlação canônica máxima entre as variáveis \tilde{x} e \tilde{y} .

$$\rho = \max_{w,v} \left(\frac{E[\tilde{x}\tilde{y}]}{\sqrt{E[\tilde{x}]^2 E[\tilde{y}]^2}} \right) \quad (1)$$

Assuma-se então que existem M estímulos, com H harmônicas, frequência de amostragem f_s e J amostras; X é o sinal EEG de I¹ canais, então de acordo com (2), Y_m é um

conjunto de sinais de referências, construídos para reconhecer as frequências f_m ($m=1,2,\dots,M$).

$$Y_m = \begin{pmatrix} \sin(2\pi f_m 1/f_s) & \dots & \sin(2\pi f_m J/f_s) \\ \cos(2\pi f_m 1/f_s) & \dots & \cos(2\pi f_m J/f_s) \\ \vdots & \vdots & \vdots \\ \sin(2\pi H f_m 1/f_s) & \dots & \sin(2\pi H f_m J/f_s) \\ \cos(2\pi H f_m 1/f_s) & \dots & \cos(2\pi H f_m J/f_s) \end{pmatrix} \quad (2)$$

De tal forma que ao aplicar (1), calculando a CCA entre os sinais de entrada e Y_m, basta calcular o valor máximo de ρ , para obtermos a frequência do sinal SSVEP.

VI. MULTIPLE SIGNAL CLASSIFICATION (M.U.S.I.C)

A pseudo-psd MUSIC, realiza a estimação espectral através dos autovalores da matriz de correlação associada aos dados observados (os três canais EEG). Seu diferencial é assumir que o número de exponenciais complexas do qual o sinal é formado é conhecido. Estudo anteriores já utilizaram este método para classificação de sinais SSVEP com sucesso [26]. Formalmente, define-se então que $x(n)$ é o sinal observado, p é o número de exponenciais complexas, v são os autovalores do subespaço do ruído branco, $M = p + 1$ e:

$$e = [1 \ e^{jw} \ e^{j2w} \ \dots \ e^{j(M-1)w}]^T \quad (3)$$

Então:

$$\hat{P}_{MU}(ejw) = \frac{1}{\sum_{i=p+1}^M |e^H v_i|^2} \quad (4)$$

O melhor resultado foi obtido com o valor p igual a 6. Desta forma, os picos observados no espectro são geralmente em 60 Hz, 120 Hz e outros picos pertinentes a frequência de estímulo, suas harmônicas ou interferências de outros estímulos. Conforme pode ser observado na Figura 4, o pico de maior destaque ocorre na frequência de estímulo, porém existe um erro associado tanto na frequência (devido a resolução espectral), quanto na potência.

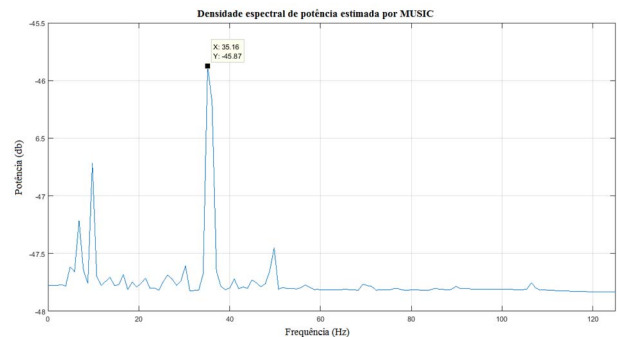


Fig. 4. Gráfico da densidade espectral de potência estimada via MUSIC. Observa-se no gráfico um pico nítido em 35,16 Hz. A frequência real do estímulo era em 35,71 Hz. Observa-se picos relativos a outras frequências de estímulo.

VII. APRENDIZAGEM POR AGRUPAMENTO

Um dos métodos de classificação mais antigos e conhecidos são as árvores de decisão. Sua maior limitação, é sua tendência

ao sobre-ajuste (*overfitting*) [27]. Um agrupamento (*ensemble*) de árvores busca reduzir este problema realizando uma média das predições de diferentes árvores. Um dos métodos mais populares, são agrupamento de árvores utilizando *bagging*. Todavia, em banco de dados com muitos exemplos, existe uma tendência de que as árvores de decisão se tornem muito similares. Em 2002, Breiman [28] propôs as florestas randômicas com o objetivo de reduzir este problema.

Neste trabalho, adotou-se a aprendizagem por agrupamento utilizando *bagging* e o conceito das florestas randômicas, escolhendo aleatoriamente um subconjunto de preditores (*features*) para construção de cada árvore. A Fig. 5 demonstra a estrutura geral do algoritmo.

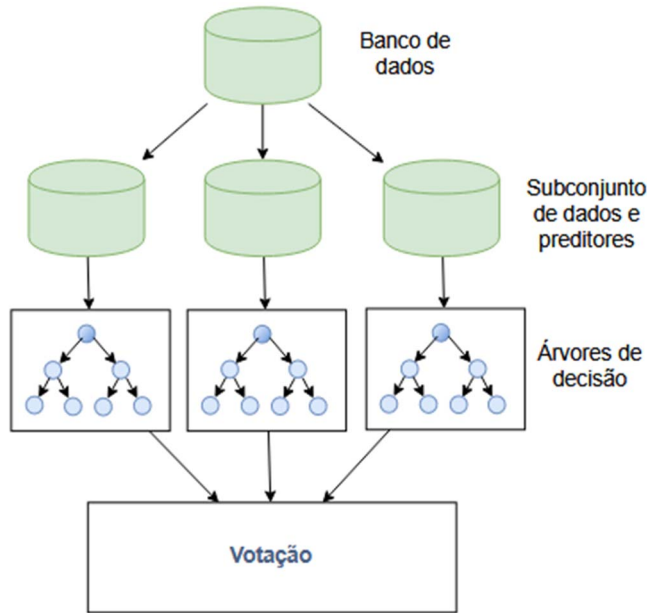


Fig. 5. Diagrama explicativo do algoritmo de classificação através de agrupamento de árvores de decisão.

O conjunto de dados do banco foi composto por 4840 amostras e 34 características. Foram testados métodos por validação cruzada *k-fold*, com *k* igual a 15. O valor de *k* foi obtido de forma empírica, alterando-se seu valor e analisando o resultado.

Também foi validado pelo método de *houdout*, e nesse caso, com 20% do banco reservado para testes, selecionados aleatoriamente a partir de todos os participantes. Adicionalmente, treinou-se um classificador com 18 participantes, excluindo-se aleatoriamente 4 pessoas do treinamento e utilizou-se esses quatro participantes separados para validação e teste.

VIII. NOVA ABORDAGEM PARA CLASSIFICAÇÃO DE SINAIS SSVEP

Muitos métodos apresentados na literatura se mostram capazes de obter bons resultados na classificação de sinais SSVEP. Entretanto, a análise da correlação canônica não se mostrou capaz de classificar corretamente sinais de alta frequência [8], [12].

O método proposto neste trabalho, utiliza classificador por agrupamento de árvores, utilizando os conceitos de *bagging* e

de florestas aleatórias. O intuito é de agregar diversas técnicas de extração de atividades SSVEP em um mesmo classificador, cada qual adequada para situações distintas.

Além disto, propõe-se algumas modificações em métodos conhecidos. No caso da CCA, propõe-se como uma melhoria que ao misturar estímulos de baixa e alta frequência, utilize-se somente as harmônicas dos estímulos de baixa frequência, conforme a Tabela I. Essa pequena modificação contribui para classificação, mas não é suficiente para alcançar uma taxa de acertos satisfatória.

TABELA I
FREQUÊNCIAS UTILIZADAS PARA CCA

| Estímulo (Hz) | Frequências (Hz) |
|---------------|----------------------------|
| 7.04 | 21.12, 28.16 e 77.44 |
| 10 | 20, 40 e 80 |
| 15.15 | 30.3, 45.45, 90.9 e 106.05 |
| 25 | 25, 50, 75 e 100 |
| 35.71 | 35.71 e 71.42 |
| 38.46 | 38.46 e 76.92 |

Considera-se a hipótese que os métodos baseados em PSD obtém melhores resultados para classificar as atividades acima de 25 Hz [29]. Dentre os métodos que estimam a PSD, sabe-se que os métodos tradicionais, baseados no método de Goertzel, aumentam sua taxa de classificação conforme utiliza-se uma janela de tempo maior [11].

Sabe-se que o método MUSIC é capaz de obter alta taxa de acertos em intervalos de tempo pequenos, mas que não há clareza quando o método MUSIC é superior a CCA [26].

Para detecção da atividade SSVEP através do MUSIC, foi calculado o valor da PSD em relação aos seus dois vizinhos maiores e menores que o ponto de interesse, conforme já realizado previamente na literatura [30]. Além disso, considerou-se um possível erro devido a resolução espectral insatisfatória, e por essa razão, este cálculo foi realizado também para os dois pontos mais próximos da frequência de interesse. O mesmo procedimento é feito para duas harmônicas. Incorporou-se no classificador o valor obtido para cada frequência e suas harmônicas.

Considera-se a hipótese que se for calculado o valor absoluto da potência (estimado por Goertzel) em uma dada frequência de estímulo e comparado esse valor ao obtido 1 segundo atrás, ocorre um grande aumento ou diminuição neste valor sempre que o usuário alternar seu foco de um estímulo para outro. Esta informação foi também incorporada ao classificador, além do próprio valor absoluto no instante de tempo analisado.

Um fator de destaque são as interferências detectadas no espectro, que ocorrem principalmente decorrentes dos estímulos próximos aos que o usuário estiver olhando. Desta forma, um efeito que pode ser negativo, torna-se uma fonte de informação importante, gerando uma redundância de informação para determinação de qual estímulo está sendo observado. Por exemplo, se o usuário estiver olhando para o estímulo de 10 Hz e próximo a ele estiverem os estímulos de 15.15 Hz e 35.71 Hz, eles geralmente estarão presentes no espectro. Entretanto, ao olhar para o estímulo de 15.15 Hz, além do estímulo de 10 Hz estar presente no espectro, outro estímulo estará presente, neste caso, 25 Hz. Isso decorre da forma como os estímulos estão arranjados no aparato.

Todavia, ao considerar todas essas variáveis, evidenciava-se a necessidade de um algoritmo de classificação de padrões. Necessita-se lidar com as seguintes circunstâncias: interferência oriunda dos demais estímulos SSVEP, separação entre estados de repouso (sem olhar para estímulos) e estados de concentração em um estímulo SSVEP e separação de atividades espontâneas EEG de atividades SSVEP.

Dentre os diversos algoritmos testados, o melhor resultado foi obtido com um agrupamento de árvores de decisão, utilizando 230 preditores e permitindo no máximo 120 divisões. Foram treinados dois classificadores, um para quando os LEDs estavam próximos e outro para quando estavam afastados.

IX. METODOLOGIA DO EXPERIMENTO

Aprovado pelo comitê de ética em pesquisa (processo 61336016.2.0000.5083), vinte e dois participantes foram recrutados. Os participantes após serem devidamente informados de seus direitos e do objetivo do trabalho, foram dispostos a uma distância de 40 cm do monitor (Uma marcação foi realizada no chão). Após a preparação adequada dos eletrodos, um dos aparatos contendo os eletrodos foi colocado ao lado do monitor. Os participantes foram instruídos de que quando escutassem um aviso sonoro, deveriam olhar para o monitor e ver qual número aparecia no centro da tela. Após observar o número, deveriam olhar para o LED associado a este número.

A ordem da sequência era sempre aleatória. A duração foi de cinco segundos olhando para cada LED. Ao terminar, a luminosidade dos LEDs era alterada. O valor era medido com auxílio de um sensor de luminosidade (GY-302). A luminosidade da sala era aproximadamente constante e similar ao longo dos dias testados. Nota-se que a sala era mantida fechada, com as luzes acesas e que os testes ocorreram todos os dias no mesmo horário (das 09h00min às 11h30min).

A luminosidade de cada LED foi alterada com auxílio de um potenciômetro. O experimento foi repetido para a nova luminosidade. Ao todo foram utilizados três valores de luminosidade para cada aparato. A ordem da sequência de luminosidades e dos aparatos utilizados foram aleatórios. Mediu-se a temperatura e humidade da sala utilizando o sensor DHT11, com o objetivo de verificar se estas variáveis não poderiam ser responsáveis pela diferença no conforto do usuário.

A Tabela II apresenta as luminosidades utilizadas. A luminosidade medida antes de ligar o estimulador, com o sensor apontado para o estimulador, que foi em média 6 lx.

TABELA II
POTENCIÔMETROS E LUMINOSIDADES UTILIZADAS

| Potenciômetro | Luminosidade 40 cm | Luminosidade 1 cm |
|---------------|-----------------------|----------------------|
| 10 k | 12 lx | 188 lx |
| 50 k | 11 lx | 56 lx |
| 90 k | 10 lx | 30 lx |

Ao final do experimento, os participantes foram solicitados a preencher um formulário confidencial, respondendo questões sobre o conforto durante o experimento. As perguntas deveriam ser respondidas realizando uma marcação em uma das opções.

Cada opção era um número de 1 a 5, sendo 5 significando muito confortável e 1 muito desconfortável. A Tabela III resume o conteúdo das perguntas.

TABELA III
FORMULÁRIO DE PERGUNTAS

| Pergunta | Descrição |
|----------|--------------------|
| 1 | Conforto geral |
| 2 | Eletrodos |
| 3 | LEDs próximos |
| 4 | LEDs afastados |
| 5 | Luminosidade maior |
| 6 | Luminosidade menor |

X. RESULTADOS

Tradicionalmente, interfaces cérebro máquina são avaliadas por sua acurácia, tempo de detecção e pela taxa de transferência de informação (*ITR - Information Transfer Rate*) [2], [31]. A ITR reúne em uma mesma medida a taxa de acertos, velocidade de detecção e quantidade de comandos disponíveis. Calcula-se a ITR pelo produto entre a taxa de bits pela quantidade de comandos por minuto. Para o cálculo da taxa de bits (valor B na Tabela IV e na Tabela V), utilizou-se a fórmula de Wolpaw [31].

Apresentam-se na Tabela IV os resultados de classificação utilizando a validação cruzada *k-fold*, com *k* igual a 35, janela de tempo de decisão de 1 segundo e o total de amostras de 4620. Nota-se que os resultados foram verificados como significativos, utilizando teste de McNemar's (duas caldas) e o teste *t* de *student* (utilizando o valor médio do erro). Em todos os testes, o valor *p* é menor que 0.0001.

TABELA IV
RESULTADOS UTILIZANDO VALIDAÇÃO CRUZADA

| Aparato | Taxa de acertos | B (Wolpaw) | ITR (bit/min) |
|----------|-----------------|---------------|------------------|
| Junto | 98.56 ± 3.10 % | 2.4428 | 146.56 |
| Separado | 99.10 ± 2.27 % | 2.4900 | 149.40 |

Os resultados da taxa de acertos são comparáveis aos resultados com o estudo publicado em 2017 que utilizou redes neurais profundas [14], todavia o referido estudo utilizou 8 canais de sinais EEG, eletrodos de cúpula com utilização de gel condutor, frequências na faixa de 9-17 Hz e 4 segundos de dados.

A Tabela V apresenta os resultados de desempenho com o classificador treinado com 80% dos dados obtidos aleatoriamente de todos os participantes.

TABELA V
RESULTADOS COM 20% DO BANCO RESERVADO

| Aparato | Taxa de acertos (20%) | B (Wolpaw) | ITR (bit/min) |
|----------|--------------------------|------------|------------------|
| Junto | 96.5 ± 2.65% | 2.2848 | 137.01 |
| Separado | 96.9 ± 4.50 % | 2.3136 | 138.82 |

Para essa forma de avaliação, apresenta-se na Figura 6 e na Figura 7 os gráficos de confusão dos dados que foram reservados para testes.

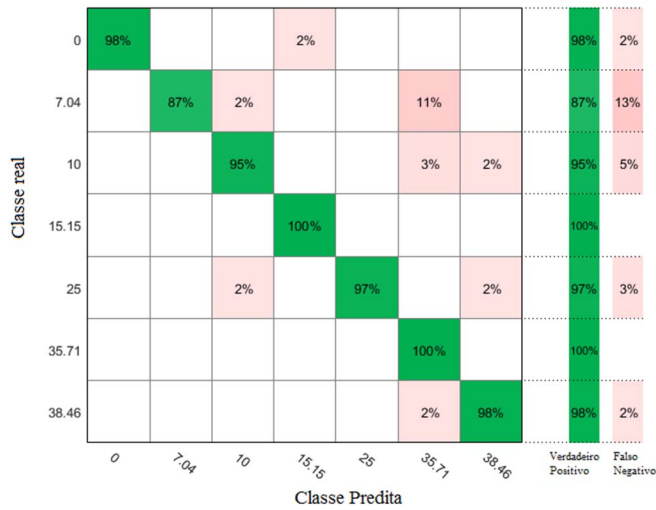


Fig. 6. Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Relativo ao classificador com os LEDs separados.



Fig. 7. Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Relativo ao classificador com os LEDs agrupados.

Na Tabela VI são destacados os melhores resultados obtidos com diversos classificadores. Todos os classificadores tiveram seus parâmetros ajustados iterativamente visando obter a maior taxa de acertos.

TABELA VI
COMPARATIVO DOS CLASSIFICADORES

| Preditores | Juntos | Separados |
|------------------------|--------|-----------|
| Agrupamento de árvores | 96.9 % | 96.5 % |
| Agrupamento KNN | 93.0 % | 93.2 % |
| KNN | 86.9 % | 89.4 % |
| Árvore de decisão | 85.4 % | 85.1 % |
| SVM (Gaussiano) | 81.5 % | 81.8 % |

Com objetivo de verificar se o método é capaz de funcionar sem necessidade de calibração individual, treinou-se o classificador com 18 participantes e foram reservados os dados de 4 pessoas. Esse processo foi repetido para 50 combinações diferentes e os resultados estão resumidos na Tabela VII. Os resultados de máximo e mínimo são pertinentes às quatro pessoas e não somente de um indivíduo, entre as quatro.

TABELA VII
RESULTADOS PARA 4 PESSOAS RESERVADAS DO TREINAMENTO

| Aparato | Média de acertos | Máximo | Mínimo |
|----------|------------------|--------|--------|
| Junto | 81.58 ± 15.64 % | 100% | 15.79% |
| Separado | 82.22 ± 16.07 % | 100% | 32.78% |

Dessa forma, demonstra-se a importância de incluir dados de treinamento do indivíduo no método apresentado neste trabalho. Em 2010, um estudo [32] apresentou uma técnica que não necessita de calibração, utilizando PCA e uma tomada de decisões em árvore, e obteve uma taxa de acerto médio de 92.25%, com mínimo de 84%. Destaca-se que esse trabalho utilizou 6 canais EEG, frequências na região *alpha* e foi testado com 8 pacientes.

Em relação ao ambiente e conforto, não foi observado correlação entre o desempenho por usuário com o número de piscadas, temperatura da sala (média de 26°), umidade (média de 68%) ou com as respostas dos formulários em relação ao conforto. Apresenta-se na Tabela VIII os resultados da quantidade média de piscadas.

TABELA VIII
MÉDIA DE PISCADAS DURANTE O EXPERIMENTO

| Aparato | Piscadas Médias -Total | Piscadas - média por segundo |
|----------|------------------------|------------------------------|
| Junto | 24.04 ± 27.68 | 0.1335 ± 0.154 |
| Separado | 25.86 ± 26.51 | 0.144 ± 0.147 |

A Tabela IX resume percentualmente as respostas obtidas através dos formulários entregues aos participantes. Como pode ser observado, 72.73% dos participantes consideraram os estímulos afastados como confortáveis e 63.64% consideram que a diminuição da luminosidade deixa estímulo mais confortável. A nota 3 pode ser compreendida como uma resposta neutra ou indiferente.

TABELA IX
RESPOSTAS DOS FORMULÁRIOS

| Pergunta | Nota 1 | Nota 2 | Nota 3 | Nota 4 | Nota 5 |
|----------|--------|--------|--------|--------|--------|
| 1 | 0.00% | 4.55% | 18.18% | 31.82% | 45.45% |
| 2 | 0.00% | 4.55% | 13.64% | 31.82% | 50.00% |
| 3 | 0.00% | 22.73% | 27.27% | 27.27% | 22.73% |
| 4 | 0.00% | 4.55% | 22.73% | 40.91% | 31.82% |
| 5 | 18.18% | 13.64% | 22.73% | 22.73% | 22.73% |
| 6 | 0.00% | 9.09% | 27.27% | 22.73% | 40.91% |

XI. CONCLUSÃO

O presente trabalho demonstrou que a combinação de diversas características do sinal EEG através de um classificador por agrupamento de árvores, possibilita a detecção de atividades SSVEP de forma eficaz e robusta.

Os resultados obtidos demonstram que a presente técnica é capaz de ser empregada em situações reais, com equipamentos relativamente simples que utilizem o ADS1299 e ao menos três eletrodos na região occipital.

Destaca-se que foi possível a detecção de atividades acima de 25 Hz, que conforme a literatura e nossos resultados demonstraram, o conforto dos usuários é consideravelmente maior.

O resultado da análise estatística dos dados mostrou que a intensidade de luz não apresentou impacto significativo na taxa de acertos e confirmou estudos anteriores de que estímulos com uma intensidade de luz maior são mais cansativos para os participantes.

Devido ao estudo ter considerado as duas disposições dos eletrodos, visando aplicações finais distintas, conclui-se da análise estatística que a distância entre os estímulos não afeta consideravelmente a taxa de detecções, todavia os estímulos mais próximos foram vistos como mais cansativos por parte dos usuários.

Como sugestão para trabalhos futuros, destaca-se a possibilidade de construção de um teclado externo utilizando LEDs, a redução da quantidade de eletrodos e a tentativa de obter um melhor modelo que generalize para indivíduos que não participaram da etapa de treinamento.

AGRADECIMENTOS

Os autores agradecem à escola de Engenharia Elétrica, Mecânica e de Computação, da Universidade Federal de Goiás (EMC/UFG) pela colaboração. Os autores agradecem à CAPES (Processo nº 1666077), o apoio recebido para o desenvolvimento deste trabalho.

REFERÊNCIAS

- [1] M. a. Lebedev and M. a. L. Nicolelis, "Brain-machine interfaces: past, present and future," *Trends Neurosci.*, vol. 29, no. 9, pp. 536–546, 2006.
- [2] C. Bondre, "Brain Computer Interfaces Using SSVEP: An Overview," vol. 1, no. 2, pp. 9–17, 2014.
- [3] C. Guger *et al.*, "How many people could use an SSVEP BCI?," *Front. Neurosci.*, vol. 6, no. NOV, pp. 2–7, 2012.
- [4] A. Luo and T. J. Sullivan, "A user-friendly SSVEP-based brain-computer interface using a time-domain classifier," *J. Neural Eng.*, vol. 7, no. 2, p. 26010, 2010.
- [5] Y. Wang, R. Wang, X. Gao, B. Hong, and S. Gao, "A practical VEP-based brain-computer interface," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 14, no. 2, pp. 234–239, 2006.
- [6] F. C. Lin *et al.*, "SNR analysis of high-frequency steady-state visual evoked potentials from the foveal and extrafoveal regions of Human Retina," *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, pp. 1810–1814, 2012.
- [7] T. Cao, F. Wan, P. U. Mak, P. Mak, M. I. Vai, and Y. Hu, "Engineering in Medicine and Biology Society Conference Flashing Color on the Performance of SSVEP-based Brain-Computer Interfaces," 2012.
- [8] G. G. Molina, "Detection of high-frequency steady state visual evoked potentials using phase rectified reconstruction," *Eur. Signal Process. Conf.*, 2008.
- [9] M. Nakanishi, Y. Wang, Y. Te Wang, Y. Mitsukura, and T. P. Jung, "Generating visual flickers for eliciting robust steady-state visual evoked potentials at flexible frequencies using monitor refresh rate," *PLoS One*, vol. 9, no. 6, 2014.
- [10] Z. Lin, C. Zhang, W. Wu, and X. Gao, "Frequency recognition based on canonical correlation analysis for SSVEP-Based BCIs," *IEEE Trans. Biomed. Eng.*, vol. 54, no. 6, pp. 1172–1176, 2007.
- [11] G. Hakvoort, B. Reuderink, and M. Obbink, "Comparison of PSDA and CCA detection methods in a SSVEP-based BCI-system," no. TR-CITIT-11-03, 2011.
- [12] C. S. Wei, Y. P. Lin, Y. Wang, Y. Te Wang, and T. P. Jung, "Detection of steady-state visual-evoked potential using differential canonical correlation analysis," *Int. IEEE/EMBS Conf. Neural Eng. NER*, pp. 57–60, 2013.
- [13] T. Sakurada, T. Kawase, T. Komatsu, and K. Kansaku, "Clinical Neurophysiology Use of high-frequency visual stimuli above the critical flicker frequency in a SSVEP-based BMI," *Clin. Neurophysiol.*, vol. 126, no. 10, pp. 1972–1978, 2015.
- [14] N. Kwak, K. Mu, and S. Lee, "A convolutional neural network for steady state visual evoked potential classification under ambulatory environment," pp. 1–21, 2017.
- [15] Y. Zhang, G. Zhou, J. Jin, X. Wang, and A. Cichocki, "Frequency Recognition in SSVEP-based BCI using Multiset Canonical Correlation Analysis," *Int. J. Neural Syst.*, vol. 24, no. 2, 2014.
- [16] Y. Zhang, J. Jin, X. Qing, B. Wang, and X. Wang, "LASSO based stimulus frequency recognition model for SSVEP BCIs," *Biomed. Signal Process. Control*, vol. 7, no. 2, pp. 104–111, 2012.
- [17] Y. Zhang *et al.*, "Multiway Canonical Correlation Analysis for Frequency Components Recognition in," *Int. Conf. Neural Inf. Process. Conf. Neural Inf. Process.*, pp. 1–9, 2011.
- [18] M. Nakanishi, Y. Wang, Y. Wang, and T. Jung, "A Comparison Study of Canonical Correlation Analysis Based Methods for Detecting Steady-State Visual Evoked Potentials," pp. 1–19, 2015.
- [19] M. Teplan, "Fundamentals of EEG Measurement," vol. 2, pp. 1–11, 2002.
- [20] M. Jukiewicz and A. Cysewska-Sobusiak, "Stimuli design for SSVEP-based brain computer-interface," *Int. J. Electron. Telecommun.*, vol. 62, no. 2, pp. 109–113, 2016.
- [21] H. Shen, K. Hüper, and M. Kleinstueber, "On FastICA algorithms and some generalisations," *Lect. Notes Electr. Eng.*, vol. 80 LNEE, pp. 403–432, 2011.
- [22] M. A. G. C. and E. L. Leber, "Noise Removal from EEG Signals in Polysomnographic Records Applying Adaptive Filters in Cascade," *Adapt. Filter. Appl.*, pp. 173–196, 2011.
- [23] G. L. Wallstrom, R. E. Kass, A. Miller, J. F. Cohn, and N. a. Fox, "Automatic correction of ocular artifacts in the EEG: A comparison of regression-based and component-based methods," *Int. J. Psychophysiol.*, vol. 53, no. 2, pp. 105–119, 2004.
- [24] Z. Cashero, "Submitted by," p. 61, 2011.
- [25] D. Diego *et al.*, "Independent component analysis-based method for electroencephalogram analysis during photic stimulation," *J. Neurosci. Methods*, vol. 235, pp. 252–261, 2014.
- [26] K. Chen, Q. Liu, Q. Ai, Z. Zhou, S. Q. Xie, and W. Meng, "A MUSIC-based method for SSVEP signal processing," *Australas. Phys. {&} Eng. Sci. Med.*, vol. 39, no. 1, pp. 71–84, 2016.
- [27] P. Yang, Y. Hwa Yang, B. B. Zhou, and A. Y. Zomaya, "A Review of Ensemble Methods in Bioinformatics," *Curr. Bioinform.*, vol. 5, no. 4, pp. 296–308, 2010.
- [28] L. Breiman, "Random forests," pp. 1–33, 2001.
- [29] C. S. Herrmann, "Human EEG responses to 1 – 100 Hz flicker: resonance phenomena in visual cortex and their potential correlation to cognitive phenomena," vol. 1, pp. 346–353, 2001.
- [30] Y. Zhang, P. Xu, D. Guo, and D. Yao, "Prediction of SSVEP-based BCI performance by the resting-state EEG network," *J. Neural Eng.*, vol. 10, no. 6, p. 066017, 2013.
- [31] P. Yuan, X. Gao, B. Allison, Y. Wang, G. Bin, and S. Gao, "A study of the existing problems of estimating the information transfer rate in online brain-computer interfaces," *J. Neural Eng.*, vol. 10, no. 2, p. 026014, 2013.
- [32] H. Cecotti, "A self-paced and calibration-less SSVEP-based brain-computer interface speller," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 18, no. 2, pp. 127–133, 2010.




Andrei Damian da Silva nascido em Tubarão, Santa Catarina, em 27/12/1990. Possui graduação em engenharia de computação pela Universidade Federal de Goiás e mestrado em engenharia elétrica e computação na Escola de Engenharia Elétrica, Mecânica e de Computação da Universidade Federal de Goiás. Atualmente trabalha no setor privado.



Gélson da Cruz Júnior nascido em Goiânia, Goiás, em 10/12/1967. Possui graduação em Engenharia Elétrica - Ilha Solteira pela Universidade Estadual Paulista Júlio de Mesquita Filho, mestrado em Engenharia Elétrica pela Universidade Estadual de Campinas e doutorado em Engenharia Elétrica pela Universidade Estadual de Campinas. Realizou Pós-

Doutorado no INESC-Porto entre 2006 e 2007. Atualmente é professor titular do curso de Pós-Graduação em Engenharia Elétrica e de Computação da Escola de Engenharia Elétrica, Mecânica e de Computação da Universidade Federal de Goiás.



Carlos Galvão Pinheiro Júnior nascido em Goiânia, Goiás em 12/04/1976. Possui graduação (1997) e mestrado (2001) em Engenharia Elétrica pela Universidade Federal de Goiás - UFG, e doutorado (2013) realizado na modalidade co-tutela pela Universidade Federal de Uberlândia - UFU e pela Université de Lorraine, na França. Atualmente é Professor Adjunto

da Escola de Engenharia Elétrica, Mecânica e de Computação (EMC) da Universidade Federal de Goiás, onde trabalha desde 2001.