

Reconhecimento do piscar intencional com perceptron multicamadas para aplicação em interfaces cérebro-computador

Bruno Stacco Oliva¹ e Francisco Javier Roperó Pélaez²

^{1,2} Universidade Federal do ABC

bsoliva@ufabc.edu.br, francisco.pelaez@ufabc.edu.br

Resumo. Neste artigo foram utilizados sinais de eletro-oculograma (EOG) presentes nos sinais de eletroencefalograma (EEG) para identificar o piscar intencional de um usuário. O sistema proposto pode fazer parte de uma interface cérebro-computador híbrida servindo como um novo canal de comunicação entre humanos e dispositivos eletrônicos. Existem métodos para fazer esta identificação com base na análise dos limites de amplitude do sinal, neste estudo é proposto um método baseado em redes neurais. Dois algoritmos são implementados, o primeiro detecta piscadas únicas enquanto o segundo detecta piscadas duplas dentro de um intervalo de tempo predefinido. Os resultados dos testes quanto à eficiência de cada um são apresentados.

Palavras chave: Interface cérebro-computador, EEG/EOG, perceptron multicamadas.

1 Introdução

Um campo de estudo atualmente em rápida evolução é a Interação Humano-Computador (IHC) onde há um constante desenvolvimento com a contínua introdução de novos meios de interação, como por exemplo, comandos de voz, toque e até mesmo interfaces de realidade virtual. O objetivo da IHC é a integração entre seres humanos e sistemas computacionais com a finalidade de realizar diferentes tarefas [1], [2]. Os métodos mais usuais nesta interação geralmente envolvem toque e contato físico com o dispositivo. No entanto outras possibilidades vêm sendo exploradas focando o desenvolvimento de novos meios de interação sem a necessidade deste contato físico com o equipamento. Neste cenário surgem as Interfaces Cérebro-Computador (ICC) [3].

As Interfaces Cérebro-Computador, também conhecidas como interface Cérebro-Máquina (ICM) são dispositivos capazes de criar um canal de comunicação com equipamentos eletrônicos utilizando como entrada a leitura de sinais elétricos gerados através da atividade cerebral. Desta forma não há dependência das vias normais de saída do cérebro como nervos periféricos e músculos [4]. O cérebro humano é composto por células nervosas denominadas neurônios. Estes são conectados uns aos

outros através de estruturas denominadas dendritos e axônios. Cada ação que desempenhamos é decorrente de alguma atividade neural, esta atividade envolve a condução de impulsos elétricos de um neurônio a outro através de suas conexões. Estes impulsos são gerados a partir da diferença de potencial decorrente do fluxo de íons nas membranas dos neurônios [5].

Posicionando eletrodos no escalpo é possível registrar os sinais elétricos decorrentes da atividade cerebral. A magnitude destes sinais é muito pequena, da ordem de alguns micro volts, sendo necessário amplificar e processar os sinais para que se possa extrair alguma informação útil. Em geral os sinais de EEG são ruidosos devido sua pequena magnitude. As fontes de contaminação por ruído podem ser diversas, divididas entre fisiológicas e não fisiológicas. As fisiológicas são associadas a própria atividade do corpo humano como por exemplo, movimentos oculares (EOG), musculares e respiratórios. Já as fontes não fisiológicas podem ser interferências eletromagnéticas de outros dispositivos, da rede elétrica ou o mau posicionamento dos eletrodos na cabeça do usuário [6], [7].

Geralmente nas interfaces cérebro-máquina baseadas em EEG os sinais de EOG são considerados grandes fontes de ruído e removidos das amostras. Mas estes sinais contém informação a respeito dos movimentos oculares que pode ser facilmente reconhecida, como por exemplo, o ato de piscar. Ao combinar os sinais de EEG e EOG é possível desenvolver uma interface híbrida capaz de enviar comandos a equipamentos eletrônicos sem a necessidade de contato físico com eles. Muitas pessoas com algum tipo de desordem neuromuscular podem se beneficiar através deste novo canal de comunicação adicionando maior qualidade em suas vidas[8], [9].

Neste artigo pretendemos investigar o uso de um leitor de eletroencefalograma para detectar o piscar voluntário dos olhos. Assim, o ato voluntário de piscar pode ser utilizado para comandar alguma ação na interface cérebro máquina. Diversos autores [8], [10], [11] propõem um método baseado em limites, denominado “*threshold method*” para identificar quando o usuário pisca. Neste método o sinal de EOG que é capturado junto ao sinal de EEG é analisado quanto à duração de seus picos positivos e negativos, assim limites são estabelecidos e se ultrapassados é dito que o usuário piscou. Geralmente estes limites são estabelecidos de forma empírica através da análise do sinal de EOG de diversos usuários. Uma das desvantagens deste método é sua pouca capacidade de generalização, conforme visto em [10] ocorreram problemas na identificação correta de alguns usuários e segundo o autor os erros foram ocasionados devido à baixa velocidade que o usuário piscava e a movimentação ocular. Ao estabelecer limites fixos alguns usuários podem ter dificuldade em utilizar o sistema se seus padrões de EOG forem muito diferentes da média utilizada na calibração do sistema.

Aqui propomos um método alternativo para identificar o piscar de um usuário. Será utilizada uma rede neural treinada para analisar os sinais de EOG e sinalizar quando o usuário piscar intencionalmente querendo enviar um comando através da interface cérebro-computador. Uma rede neural artificial é um sistema de processamento de informação que tem algumas características em comum com redes neurais biológicas. Esses sistemas podem ser utilizados na resolução de diversos problemas, entre eles achar soluções para problemas de otimização, classificar e reconhecer padrões e fazer associações entre padrões de entrada e saída [12]. Ao piscar surgem padrões específi-

cos no sinal de EEG e as redes neurais tem boa capacidade para reconhecer e classificar padrões. O objetivo será desenvolver um sistema capaz de identificar quando o usuário piscar em tempo real, através dos dados coletados pelo leitor de eletroencefalograma.

2 Materiais e métodos

2.1 Equipamento EEG escolhido

Para desenvolver o sistema de detecção do piscar voluntário dos olhos através da análise dos sinais de EOG presentes nos sinais de EEG foi necessário capturar estes sinais elétricos. Para desempenhar tal tarefa utilizou-se o Mindwave Mobile fabricado pela Neurosky, esta é uma empresa especializada no desenvolvimento de biosensores. O MindWave é um leitor de EEG comercial, de baixo custo (cerca de US\$100,00) e fácil manuseio, pois além de ser portátil e sem fios, possui apenas dois eletrodos secos que não precisam da aplicação de gel condutor durante sua utilização.

O equipamento fica posicionado na cabeça do usuário de forma que o eletrodo principal fica localizado ao lado esquerdo da testa acima dos olhos (ponto fp1 segundo o sistema internacional 10-20 de posicionamento de eletrodos para EEG) e o eletrodo de referência é conectado a orelha esquerda através de um clip. Este leitor de EEG fornece três informações: os sinais elétricos gerados devido à atividade cerebral cujos valores de amplitude variam entre $1\mu\text{V}$ e $100\mu\text{V}$ em uma pessoa saudável [13] e o estado mental do usuário que é informado através dos níveis de “atenção” e “meditação”.

Segundo o fabricante [14] o algoritmo que mede a atenção indica a intensidade do foco mental, valor varia entre 0 e 100 e aumenta a medida que o usuário foca em um único pensamento ou objeto e decai quando está distraído. Já o algoritmo responsável por medir a meditação indica o nível de relaxamento mental, o valor também varia entre 0 e 100 aumentando quando o usuário relaxa e diminuindo quando está estressado ou agitado. As duas informações mencionadas acima são amostradas a uma taxa de 1 Hz, ou seja as atualizações ocorrem a cada um segundo.

Já o sinal elétrico medido pelo leitor é amostrado a 512 Hz, ou seja, são realizadas 512 amostras por segundo. A amostragem é realizada através de um conversor analógico-digital (AD) de 12 bits. Os valores amostrados podem ser acessados através do dispositivo antes de serem processados pelo algoritmo que detecta o estado mental do usuário, e por isso recebe o nome de *raw data*, em tradução literal do inglês algo como dados brutos. Através da equação (1) é possível transformar o *raw data* em valores de tensão novamente, cujo resultado fornece a tensão em volts.

$$V = (\text{raw data} \times 1,8/4096)/2000 \quad (1)$$

onde 1,8 é a tensão de entrada, 2000 o ganho do amplificador interno de sinal e 4096 é a resolução do conversor AD [15]. Neste estudo usamos apenas o *Raw data* para alimentar a entrada da rede neural.

A comunicação com o MindWave é feita através de bluetooth, o protocolo de comunicação utilizado é proprietário da Neurosky e está disponível para consulta no site do fabricante [16]. Para fazer a leitura dos dados fornecidos pelo leitor de EEG foi utilizada uma placa de desenvolvimento micro controlada Arduino UNO. Através de um módulo bluetooth é feita a comunicação da placa com o MindWave. Na figura 1 são ilustrados o leitor de EEG MindWave mobile, a placa e desenvolvimento e o módulo bluetooth utilizado.




Fig. 1. MindWave mobile a direita e placa de desenvolvimento conectada ao módulo bluetooth a esquerda.

2.2 Treinando a rede neural e detectando o ato de piscar

Ao piscar, os sinais de EOG, devido ao movimento dos olhos, são capturados junto aos sinais de EEG através do MindWave. Este padrão pode reconhecido visualmente pois ao piscar as amplitudes dos sinais registrado pelo leitor de EEG se alteram significativamente. Para identificar quando um usuário pisca intencionalmente foi utilizada uma rede neural do tipo perceptron multicamadas que depois de treinada é capaz de reconhecer tais padrões. Na figura 2 podemos visulaizar o padrão que ocorre ao piscar a partir do isntante 0,7s. Surgem picos no sinal que ultrapassam os +200uV e -100uV.

As entradas da rede são alimentadas da seguinte forma:

1. Um vetor contendo 45 amostras do sinal de EEG fornecido pelo Mindwave é montado, a janela de amostragem pode ser visualizada na figura 3.
2. Este vetor é normalizado utilizando a maior amostra referente ao pico negativo da onda.
3. Um outro vetor é montado contendo as amostras normalizadas e a magnitude do pico negativo. Este valor é normalizado em função do maior valor obtido em uma calibragem realizada pelo usuário ao utilizar o sistema. Esta

calibragem dura 5 segundos e o usuário pisca algumas vezes, então é registrado o menor valor do sinal que no caso é o pico negativo. Este segundo vetor possui 46 elementos e alimenta as entradas da rede.

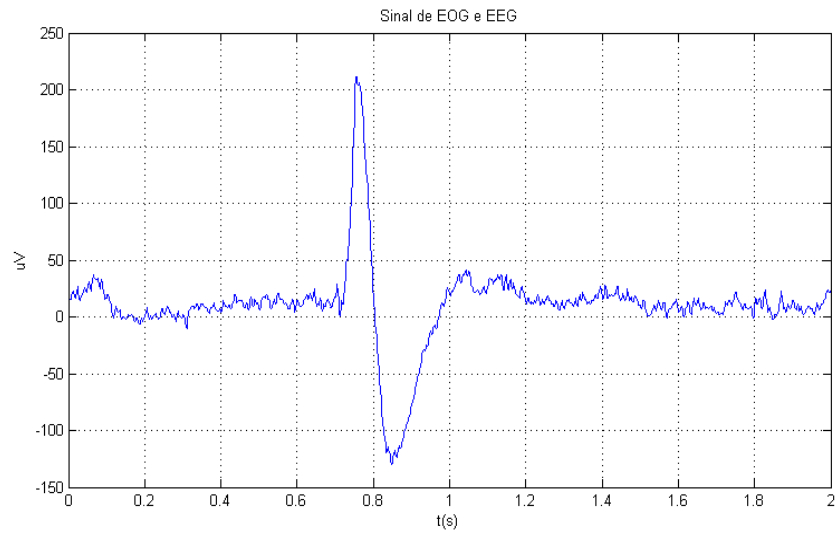


Fig. 2. Sinal de EOG junto ao sinal de EEG obtido ao piscar os olhos

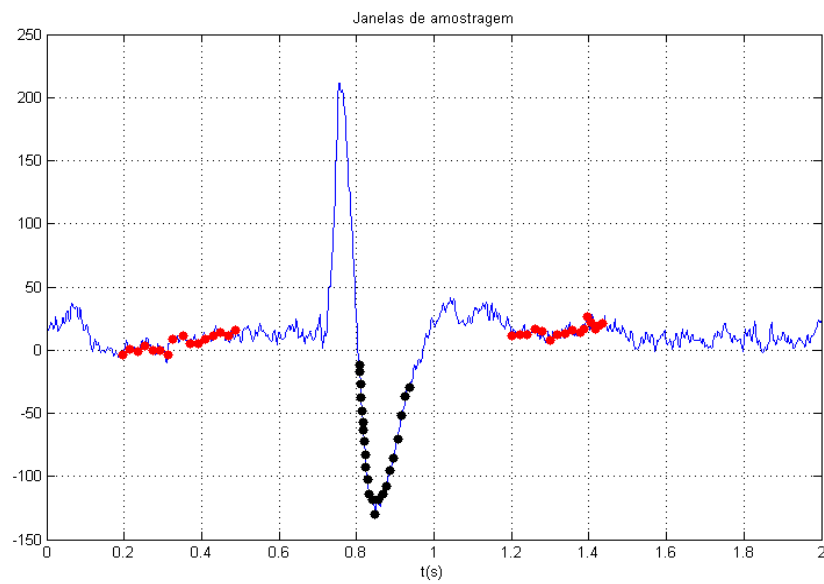


Fig. 3. Janelas de amostragem

Na figura 3, amostras na cor vermelha correspondem ao sinal de EEG sem o EOG proveniente do piscar dos olhos, já as amostras na cor preta temos os sinais de EEG e EOG juntos, mais especificamente a parte negativa do sinal de EOG. A rede neural foi treinada para reconhecer o padrão de amostras da parte negativa do sinal de EOG e indicar que o usuário piscou. Ao reconhecer os padrões fornecidos pelas amostras em vermelho a rede não indica que detectou o ato de piscar.

A implementação da rede neural na placa de desenvolvimento Arduino foi realizada através de uma biblioteca chamada Neurona [17]. A rede possui 46 entradas, 3 neurônios na camada intermediária e um neurônio na saída. A topologia da rede é mostrada na figura 4.




Fig. 4. Topologia da rede neural utilizada

O neurônio na saída da rede irá disparar, ou seja, terá seu valor próximo a 1 quando for detectado que o usuário piscou. A rede foi treinada com um conjunto de dados obtido através de uma gravação feita com o MindWave onde o usuário piscou 10 vezes. Durante a coleta dos dados o usuário ficou em posição sentada sem se mover e o intervalo entre uma piscada e outra foi definido a critério do usuário. A gravação tem duração de aproximadamente 18 segundos e foram amostradas cerca de 9216 valores para o *raw data*.

Este tipo de rede tem o aprendizado supervisionado realizado através do algoritmo de *backpropagation*. Durante a aprendizagem aplica-se uma entrada na rede e a saída desejada é forçada para que os pesos das conexões entre os neurônios se ajustem. Este processo foi realizado com o auxílio de um computador através de uma ferramenta online disponibilizada no site do desenvolvedor da biblioteca Neurona [18]. O computador possui uma capacidade de processamento muito superior a do microcontrola-

dor, diminuindo assim o tempo gasto durante o treinamento da rede. O microcontrolador por sua vez roda apenas o modo de operação da rede quando já temos os pesos de cada conexão definidos.

A rede foi treinada com uma taxa de aprendizado igual a 0,005 e o critério de parada foi o erro médio quadrático menor do que 0,001, estes parâmetros podem ser ajustados na ferramenta empregada no treinamento da rede. No total foram necessárias 125682 épocas para finalizar a etapa de treino. Com os pesos das conexões definidos pode-se prosseguir a etapa seguinte: inserir estes dados na rede neural programada no microcontrolador e avaliar os resultados e avaliar o funcionamento da rede.

O conjunto de hardware do sistema que contém o microcontrolador e o módulo bluetooth foi montado em uma pequena caixa plástica para uma maior proteção dos circuitos eletrônicos, figura 5. Além disso foram adicionados alguns LEDs e um pequeno alto falante para indicar algumas informações ao usuário. O LED central verde se acende quando o MindWave está conectado ao microcontrolador e corretamente posicionado na cabeça do usuário. Os LEDs vermelhos são utilizados para indicar a calibração do sistema que deve ser feita logo no início da utilização onde o usuário deve piscar algumas vezes seguidas. Durante a calibração que dura 5 segundos os LEDs se acendem e apagam em um padrão circular no sentido horário. O alto falante emite um sinal sonoro (“bip”) cada vez que é identificado que o usuário piscou. O volume do som pode ser ajustado através de um potenciômetro.



Fig. 5. Protótipo montado

2.3 TESTES REALIZADOS

O desempenho do sistema proposto foi avaliado através de dois testes:

Teste 1: Consiste em piscar intencionalmente 20 vezes, o intervalo entre uma piscada e outra é definido a critério do usuário. Este teste foi repetido três vezes. Através deste teste pretende-se avaliar a eficiência do sistema em reconhecer o piscar intencional. Os resultados são apresentados nas tabelas 1 e 3.

Teste 2: Consiste no usuário apenas usar o leitor de EEG e não piscar intencionalmente, apenas piscar involuntariamente sem realizar movimentos bruscos durante 2 minutos. Este teste pretende avaliar a capacidade do sistema de evitar falsos positivos, os resultados são apresentados nas tabelas 2 e 4.

Os testes foram realizados apenas com um usuário, no caso o autor do artigo.

3 RESULTADOS

As tabelas a seguir apresentam os resultados obtidos através dos testes:

Tabela 1. – Resultados do primeiro teste

Rodada	Piscadas	Corretas	Perdidas	Falsos Positivos	Acurácia
1	20	19	1	0	95%
2	20	19	1	2	95%
3	20	18	2	0	90%

Tabela 2. Resultados do segundo teste

Falsos positivos	2
------------------	---

Durante os primeiros testes realizados a rede neural se mostrou capaz de detectar o piscar dos olhos. Os melhores resultados foram das rodadas 1 e 2 com uma porcentagem de 95% de acerto. O pior resultado foi da terceira rodada com acerto de 90%. A acurácia acumulada das três rodadas é mostrada abaixo:

$$\text{Acurácia das três rodadas} = ((0,95 + 0,95 + 0,9)/3) \times 100 = 93,34 \% \quad (2)$$

Ainda durante o primeiro teste ocorreram 2 falsos positivos na rodada número 2, ou seja, o sistema detectou uma piscada mas essa não era a real intenção do usuário. Já no segundo teste, onde o usuário não piscou intencionalmente nenhuma vez durante 2 minutos ocorreu uma detecção. Estes falsos positivos podem estar associados ao ato de piscar involuntário, bem como outras interferências no sinal de EEG que podem ser causadas por movimentos do usuário. Na figura 5 são apresentados os dois

padrões gerados pelo ato involuntário de piscar (no instante 0,5s) e a piscada intencional (aproximadamente no instante 1,1s), estes dois padrões são semelhantes podendo induzir a rede neural a erro. Em [8], o autor cita que não é uma tarefa fácil distinguir entre a piscada involuntária e a piscada intencional.

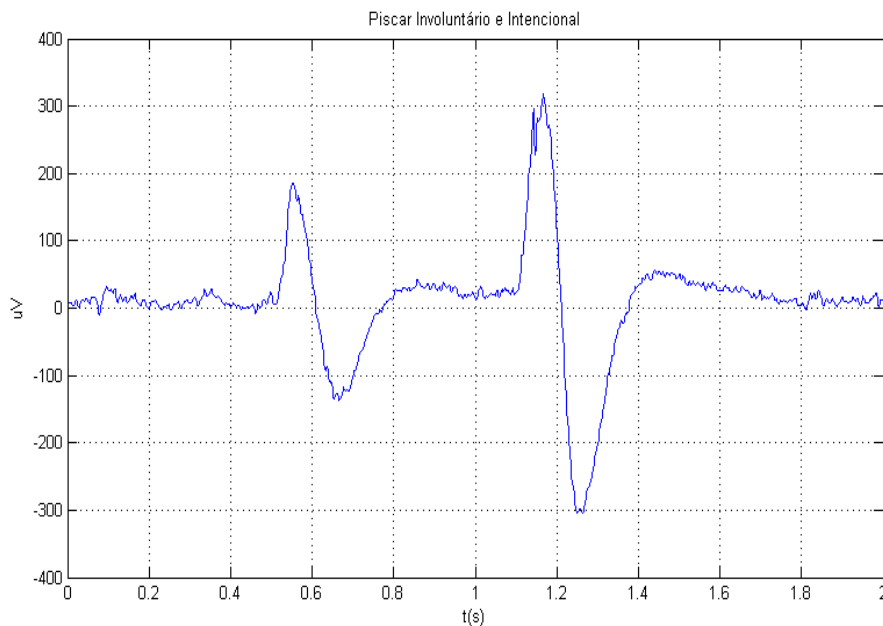


Fig. 5. Comparação nas formas de onda do piscar involuntário (0,5s) e intencional (1,1s).

Os falsos positivos não são desejáveis pois o sistema pode se tornar menos robusto ao interpretar um falso positivo como uma intenção de comando do usuário. Assim, um novo algoritmo foi proposto a fim de evitar falsos positivos e garantir que a interface interprete apenas o piscar voluntário dos olhos com uma certeza ainda maior. Neste novo algoritmo para que seja identificada a piscada o usuário deve piscar duas vezes consecutivas dentro de um intervalo de tempo predefinido. Um teste para definir o melhor valor deste intervalo foi realizado. Este teste consistiu em avaliar o percentual de acerto do sistema, similar ao teste 1, variando o intervalo predefinido entre uma piscada e outra. Segundo a literatura [11], a duração média de uma piscada é entre 100 e 400 ms, por isso foi escolhido o intervalo de 100 a 800 ms espaçados de 100 ms para testes. A figura 6 apresenta os resultados obtidos através do teste.

O melhor resultado encontrado foi um intervalo de 600ms, com uma taxa de acerto de 93,3%. Isso significa que para o sistema interpretar que o usuário piscou é necessário que ele pisque duas vezes seguidas, com um intervalo máximo de 600ms entre a primeira e a segunda piscada. Os testes 1 e 2 foram realizados novamente e os resultados apresentados nas tabelas 3 e 4:




Fig. 6. Resultado do teste para melhor ajuste do intervalo de tempo entre as duas piscadas consecutivas.

Tabela 3. Resultados do teste 1 repetido com novo algoritmo

Rodada	Piscadas	Corretas	Perdas	Falsos Positivos	Acurácia
1	20	17	3	0	85%
2	20	19	1	0	95%
3	20	18	2	0	90%

Tabela 4. Resultados do teste 2 repetido com novo algoritmo

Falsos positivos	0
------------------	---

O segundo algoritmo proposto apresentou um resultado ligeiramente inferior ao primeiro. O melhor resultado foi obtido na rodada 2 com 95% de acerto, e o pior resultado na rodada 1 com uma taxa de acerto de 85%. Em compensação não ocorreram falsos positivos, o que é interessante do ponto de vista de robustez do sistema. A acurácia acumulada das três rodadas é apresentada abaixo:

$$\text{Acurácia das três rodadas} = ((0,85 + 0,95 + 0,9)/3) \times 100 = 90 \% \quad (3)$$

A perda de eficiência observada através dos teste com o segundo algoritmo proposto se deve ao fato de o usuário ter que piscar duas vezes e dentro de pequeno intervalo de tempo exigindo uma maior atenção de quem estiver utilizando o dispositivo. Com um pouco de treinamento seria possível melhorar este desempenho. Já os falsos positivos foram eliminados durante os testes tornando o sistema mais robusto.

4 CONCLUSÕES

Neste estudo foi desenvolvido um sistema para detectar o piscar dos olhos através dos sinais de EOG presentes nos sinais de EEG. Para isso foi utilizada uma rede neural treinada para reconhecer os padrões gerados quando o usuário pisca. Apesar de os testes serem realizados com apenas um usuário e não possuírem relevância estatística, pode-se observar que a rede neural foi capaz de identificar padrões que surgem junto aos sinais de EEG. Durante os primeiros testes o sistema apresentou alguns falsos positivos, ou seja, indicava que o usuário piscou mesmo quando esta não era a intenção. Para minimizar estas ocorrências um novo algoritmo foi proposto onde o usuário precisa piscar duas vezes consecutivas em um intervalo predefinido para que o sistema detecte a piscada. Este novo método se mostrou eficaz em evitar os falsos positivos trazendo maior robustez e confiabilidade ao sistema.

Referências

1. B. S. Barbosa, S.D.J.; Silva, *INTERAÇÃO HUMANO-COMPUTADOR*, 1st ed. Editora Campus-Elsevier, 2010.
2. M. Hassib, “Mental task classification using single-electrode brain computer interfaces,” 2012.
3. K. DOBOSZ and P. WITTCHEM, “Brain-Computer Interface for Mobile Devices,” *J. Med. INFORMATICS Technol.*, vol. 24, 2015.
4. A. Vallabhaneni, T. Wang, and B. He, “Neural Engineering,” in *Neural Engineering*, vol. 58, no. 12, 2014, pp. 7250–7.
5. R. R. B. A. HASSAN, “Eeg Signal Classification for Wheelchair Control Application,” Universiti Tun Hussein Onn Malaysia, 2015.
6. J. Yang, X. Su, D. Bai, Y. Jiang, and H. Yokoi, “Hybrid EEG-EOG system for intelligent prosthesis control based on common spatial pattern algorithm,” *2016 IEEE Int. Conf. Inf. Autom.*, no. August, pp. 1261–1266, 2016.
7. J. Lin, X. Sun, J. Wu, S. Chan, W. Xu, and A. S. Modeling, “Removal of Power Line Interference in EEG Signals with Spike Noise Based on Robust Adaptive Filter,” pp. 2709–2712, 2016.
8. J. Ma, Y. Zhang, A. Cichocki, and F. Matsuno, “A novel EOG/EEG hybrid human-machine interface adopting eye movements and ERPs: Application to robot control,” *IEEE Trans. Biomed. Eng.*, vol. 62, no. 3, pp. 876–889, 2015.
9. D. Bright, A. Nair, D. Salvekar, and S. Bhisikar, “EEG-based brain controlled prosthetic arm,” *2016 Conf. Adv. Signal Process.*, pp. 479–483, 2016.

10. B. Jammes, H. Sharabty, and D. Esteve, "Automatic EOG analysis: A first step toward automatic drowsiness scoring during wake-sleep transitions," *Somnologie*, vol. 12, no. 3, pp. 227–232, 2008.
11. A. Bulling, J. A. Ward, H. Gellersen, and G. Tröster, "Eye movement analysis for activity recognition using electrooculography," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 33, no. 4, pp. 741–753, 2011.
12. L. V. Fausett, *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. 1994.
13. C. Umale, "Feature Extraction Techniques and Classification Algorithms for EEG Signals to detect Human Stress - A Review," vol. 5, no. 1, pp. 8–14, 2016.
14. Neurosky, "Get to market faster with NeuroSky pre-built algorithms.," 2017. [Online]. Available: <http://neurosky.com/biosensors/eeg-sensor/algorithms/>. [Accessed: 07-Mar-2017].
15. Neurosky, "How to convert raw values to voltage?," 2017. [Online]. Available: <http://support.neurosky.com/kb/science/how-to-convert-raw-values-to-voltage>. [Accessed: 27-Jun-2017].
16. Neurosky, "ThinkGear Serial Stream Guide," 2017. [Online]. Available: http://developer.neurosky.com/docs/doku.php?id=thinkgear_communications_protocol. [Accessed: 07-Mar-2017].
17. C. B. Moretti, "Neurona - Artificial Neural Networks for Arduino," 2016. [Online]. Available: <http://www.moretticb.com/blog/neurona-neural-networks-for-arduino/>. [Accessed: 18-Jul-2017].
18. C. B. Moretti, "MLP Topology Workbench - A playground for Multi-Layer Perceptrons MACHINE-LEARNING MLP Topology Workbench - A playground for Multi-Layer Perceptrons," 2017. [Online]. Available: <http://www.moretticb.com/blog/mlp-topology-workbench-a-playground-for-multilayer-perceptrons/>. [Accessed: 18-Jul-2017].