

Braço Robótico controlado por Interface Cérebro-Computador

Thiago Hashiya Oda e André Kazuo Takahata

Resumo— Esse projeto tem como objetivo estudar um braço controlado por interface cérebro-máquina (BCI) baseada em sinais de eletroencefalograma (EEG). O projeto constituiu na construção de um braço robótico que pode ser controlado por sinais neurais, de modo a executar um grupo de ações, como pegar e deslocar um objeto entre duas posições pré-definidas. O braço robótico é do modelo do projeto MeArm e utiliza um Arduino para controle. Com o uso do Octave foi criado um programa que permite o comando do braço com o uso de dados de EEG previamente adquiridos, simulando o controle do braço pelo usuário.

Palavras-Chave—Interface Cérebro-Máquina, Eletroencefalograma, Arduino.


Abstract— This project aims to study an arm controlled by a brain-computer interface (BCI) based on electroencephalogram (EEG) signals. The project involved the construction of a robotic arm that can be controlled by neural signals to perform a group of actions, such as picking up and moving an object between two predefined positions. The model of the robotic arm is from the MeArm project and it uses an Arduino for control. We used Octave to create a program that commands the arm using previously acquired EEG signals, thus simulating the control of the arm by the user.

Keywords— Brain Computer Interface, Electroencephalogram, Arduino.

I. INTRODUÇÃO

Esse projeto teve como objetivo o desenvolvimento de um braço robótico controlado por uma interface cérebro-máquina (BCI) baseada em sinais de eletroencefalograma (EEG), que tem como objetivo, mapear os sinais característicos de EEG gerados pelo usuário e transformar em comandos para dispositivos sem o uso dos músculos ou do sistema nervoso periférico como mostrado na Figura 1.

Figura 1— Funcionamento de uma BCI




O paradigma utiliza é baseado nos potenciais visuais evocados em regime permanente (SSVEP), em que diferentes comandos são associados a estímulos visuais de frequências diferentes. Ao usuário focar a atenção em um desses estímulos ocorre uma resposta em mesma frequência que pode ser detectada no EEG (o SSVEP) [2]. Nesse projeto, os experimentos realizados são do tipo offline com os sinais obtidos da base de dados de [2].

Thiago Hashiya Oda, Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas (CECS), Universidade Federal do ABC, Santo André-UFABC, e-mail: hashiya.oda@aluno.ufabc.edu.br; André Kazuo Takahata, Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas (CECS), Universidade Federal do ABC, Santo André-UFABC, e-mail: andre.t@ufabc.edu.br.

II. METODOLOGIA

Para a aquisição dos sinais de EEG em [2], foram utilizados 16 eletrodos posicionados conforme a Figura 2. O procedimento foi realizado em 15 sujeitos, em que para cada um foi realizado o experimento 48 vezes por 6 segundos cada sessão. Os *trials* foram divididos igualmente entre as 4 classes de estímulos (10Hz, 11hz, 12hz e 13Hz).

Figura 2 – Posicionamento dos 16 eletrodos [2]




Os sinais obtidos são pré-processados com o filtro espacial CAR, o qual tem como objetivo a redução das componentes comuns dos canais, e manter as componentes específicas relativas à posição de cada eletrodo [3]. O CAR Pode ser descrito por:

$$x_i^{CAR} = x_i^{ER} - \sum_{j=1}^N \frac{x_j^{ER}}{N},$$

onde x_i^{CAR} é um vetor com as amostras do sinal filtrado, x_i^{ER} é um vetor com as amostras do sinal do i -ésimo eletrodo e N é o número total de eletrodos. Na Figura 3 são mostrados dois espectros em magnitude obtidos com o uso da transformada rápida de Fourier (*fast Fourier transform*, FFT), em que o primeiro corresponde ao sinal original e o segundo é o mesmo sinal, porém utilizando o CAR para um estímulo de 10Hz. É possível observar como o CAR eliminou o pico em 11 e 12Hz que poderiam ocasionar algum erro de classificação. Como esses picos são componentes comuns, eles foram eliminados e foi evidenciada a amplitude de 10Hz.

Figura 3 - Sinal com e sem o filtro CAR do Sujeito 01, Canal 07 e trial 07




Para o projeto, foi escolhido como braço robótico o projeto *open source* MeArm, de fácil aquisição e que pode ser controlado com a placa Arduino. No caso do projeto já tínhamos disponível um kit feito em MDF e cortado a laser. Um braço semelhante em acrílico montado pode ser visto na Figura 1

O classificador desenvolvido funciona a partir do sinal de EEG de um *trial* de um sujeito por meio da obtenção do espectro para cada canal com o uso da FFT. A partir da

amplitude das componentes em 10Hz, 11Hz, 12Hz e 13Hz de cada canal, é selecionada a frequência que possui maior amplitude. Após todos os canais serem analisados, por um sistema de votação, a frequência mais ocorrente para esse *trial* passa corresponder à classe estimada pelo classificador. Na Figura 4, é possível ver um exemplo em que de todos os 16 canais, 12 tem um pico em 10Hz. Utilizando o método de votação, a classe mais ocorrente entre os canais é selecionada como classe do *trial*. Então nesse caso como quase todos possuem uma amplitude maior em 10Hz, o *trial* é classificado como de classe 10Hz.

Figura 4 – Espectro em magnitude dos 16 eletrodos do Trial 7 do Sujeito 01 obtida com o uso do FFT



Com a classificação feita, o Octave comunica com o Arduino através de uma biblioteca padrão. Para cada classificação o Octave associa a um ponto específico da área de trabalho. Esse ponto então é lido e enviado em formato de comando para o braço mecânico operar uma devida ação.


O programa primeiro inicializa com dois sinais aleatórios. Esses dois sinais, então, são classificados pelo algoritmo de classificação. Após esses sinais serem classificados, eles são designados como ponto inicial e final conforme a Tabela 1.

Tabela 1 - Relação da classe com os pontos estipulados

Classificação	10Hz	11Hz	12Hz	13Hz
Ponto	A	B	C	Pote

Com os pontos designados, o Arduino comanda a cinemática do braço pegando o objeto no ponto inicial, e levando até o ponto final. A Figura 5 mostra a área de trabalho do braço e os respectivos pontos.

Figura 5 - Área de trabalho do braço e os pontos onde ele atua (feito no Autodesk Autocad 2019)



III. RESULTADOS E DISCUSSÃO

Após os testes, o algoritmo obteve uma acurácia média de 82% com um desvio padrão de 5,1%. A Tabela 2 mostra a acurácia de cada sujeito e a acurácia média de todos os sujeitos combinados.

Tabela 2 - Acurácia do classificador para cada sujeito

Sujeito	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Acurácia	100%	58%	67%	100%	90%	65%	33%	98%	73%	88%	96%	98%	75%	98%	98%
Média	82%														
Desvio	0,05														

Esse resultado mostra que esse classificador é promissor quando considerado que é um modelo de classificação único e

é utilizado igualmente para todos os sujeitos, isto é, ele é bem menos refinado que outros modelos de classificação [2].

Como o Sujeito 1 obteve uma classificação de 100%, ele foi selecionado para testar a cinemática do braço robótico. Foram realizados testes com 3 objetos diferentes, duas bolas de isopor com diâmetros diferentes, e um cilindro de plástico de 20mm de altura. Os resultados abaixo nas Tabelas 3, 4 e 5 são relacionados à taxa de sucesso do braço para deslocar o objeto até o ponto desejado. É possível observar que para o projeto, a bola de isopor com menor diâmetro possui uma taxa de acerto maior, cerca de 93% de sucesso. Um problema observado em alguns casos, o braço robótico não conseguia levar ou segurar o objeto de maneira segura, assim fazendo que o objeto caísse ou rolasse durante o percurso. Para o cilindro isso ocorreu menos vezes visto que possui uma base reta. A bola com maior diâmetro escorregava da garra e rolava para fora do ponto após ser depositado.

Tabela 4 – Acertos com a bola de isopor de 35mm de diâmetro.

Percurso	AB	AC	BA	BC	CA	CB	AP	BP	CP
Acertos	10	9	6	8	6	9	9	10	8
Erros	0	1	4	2	4	1	1	0	2
% de acerto	100%	90%	60%	80%	60%	90%	90%	100%	80%

Tabela 5 – Acertos com a bola de isopor de 25mm de diâmetro.

Percurso	AB	AC	BA	BC	CA	CB	AP	BP	CP
Acertos	10	10	8	10	10	9	9	10	8
Erros	0	0	2	0	0	1	1	0	2
% de acerto	100%	100%	80%	100%	100%	90%	90%	100%	80%

Tabela 6 – Acertos com o cilindro de 20mm de altura.

Percurso	AB	AC	BA	BC	CA	CB	AP	BP	CP
Acertos	10	10	10	9	10	8	8	8	10
Erros	0	0	0	1	0	2	2	2	0
% de acerto	100%	100%	100%	90%	100%	80%	80%	80%	100%

Após algumas pesquisas na literatura, a taxa de sucesso de 93% observada no cenário com a bola de isopor de 25mm de diâmetro é aceitável visto que entre [4] [5] e [6], a maior taxa de acerto foi de 92%. Com isso, pode ser considerado que no caso analisado, o classificador apresenta um desempenho na mesma ordem de grandeza de outros trabalhos previamente publicados na literatura, entretanto, o sistema pode ser melhorado utilizando-se materiais mais adequados ou um controlador de maior capacidade de processamento como o Raspberry.

IV. AGRADECIMENTOS

Agradecemos ao Professor Diogo Coutinho Soriano e ao Sr. Inácio da Silva Júnior por disponibilizar os dados de [2]. Este trabalho foi financiado pelo Programa Pesquisando Desde o Primeiro Dia da UFABC (PDPD/UFABC).

REFERÊNCIAS

[1] McFarland DJ, McCane LM, David SV, Wolpaw JR. Spatial filter selection for EEG-based communication. *Electroencephalography and Clinical Neurophysiology*; 1997; 103: 386-394.
 [2] DA SILVA JUNIOR, José Inácio. Comparativo de desempenho de sistemas bci-ssvep off-line e em tempo de execução utilizando técnicas de estimação de espectro e análise de correlação canônica. Dissertação de mestrado – Engenharia Biomédica, CECS, UFABC, 2017.
 [3] XINYANG et al. Analysis the effect of PCA for feature reduction in non-stationary EEG based motor imagery of BCI system. *Optik - International Journal for Light and Electron Optics*, v. 125, Issue 3, February 2014, Pages 1498–1502.
 [4] HE, Bin et al. Noninvasive electroencephalogram based control of a robotic arm for reach and grasp tasks. 2016.
 [5] ORTNER, Rupert et al. An SSVEP BCI to control a hand orthosis for person with tetraplegia. 2011.
 [6] ZHAO, Bing et al. Control of a 7-DOF robotic arm system with an SSVEP based BCI. 2018.