

Modelo 3D e Reconhecimento de Gestos por sEMG no Desenvolvimento de uma Prótese Virtual de Mão

Andressa Lemes S. Dias, Gustavo Z. Cervera, Maria Claudia F. Castro

Centro Universitário FEI, São Bernardo do Campo, Brasil

mclaudia@fei.edu.br

Abstract – *Este trabalho descreve a interação entre um modelo 3D de mão e punho e um sistema de reconhecimento de gestos baseado em sEMG usando a plataforma Myo Gesture Control Armband System, visando a construção de uma prótese transradial virtual para treinamento de amputados. Os movimentos reconhecidos e reproduzidos foram Mão Aberta, Preensão Cilíndrica, Pressão Lateral, Pinça e Apontando. Foram utilizados dois algoritmos de classificação baseados em k-vizinhos mais próximos e redes neurais. Apesar de, individualmente, as taxas de acerto da rede neural terem sido superiores, os resultados não apresentaram diferença estatisticamente significativa para $p > 0,05$.*

Palavras-chave: *prótese virtual, sEMG, reconhecimento de padrões.*

Introdução

A amputação transradial, mesmo que unilateral, dificulta a execução de atividades do cotidiano, pela falta de uma das mãos. Próteses estéticas, ou com controle por tração de cabos, também chamadas de próteses convencionais, não restauram satisfatoriamente a função perdida [1]. Atualmente, as próteses eletrônicas do mercado usam sinais de eletromiografia de superfície (sEMG) como forma de interação sujeito-máquina, na indicação da intenção do sujeito quanto ao movimento a ser realizado [2, 3]. Costumeiramente, são utilizados dois canais de sEMG, um na musculatura flexora e outro na musculatura extensora. Contudo, essa combinação é incapaz de comandar vários movimentos com a acurácia requerida. Por outro lado, a necessidade de se comandar cada vez mais movimentos fez com que os sistemas mais modernos migrassem para controle por aplicativos em smartphone, diminuindo o controle natural, espontâneo e intuitivo desejado para as próteses [4].

É pressuposto que os padrões de sinais de sEMG no antebraço contêm informações sobre os movimentos desejados da mão e do punho. Usando uma técnica de reconhecimento de padrões, diferentes características dos padrões de

sEMG podem ser usadas para identificar uma variedade maior de movimentos [1,5].

A motivação do presente projeto encontra-se na necessidade de realização de um treinamento do sistema de reconhecimento de padrões, com a realimentação para o usuário da prótese, de forma que ele próprio consiga se treinar para gerar padrões de contração consistentes e repetitivos para cada um dos movimentos pretendidos. Ao mesmo tempo que o sistema de reconhecimento pode se beneficiar com padrões de sinais mais consistentes, uma acurácia de reconhecimento maior beneficia o usuário.

Para tanto, além do uso de algoritmos precisos de classificação de padrões, é interessante o uso, também, de modelos 3D na elaboração das chamadas próteses virtuais, para melhor visualização das respostas de movimentos e interação com o usuário durante o treinamento.

Dentro deste contexto, o presente trabalho descreve a interação entre um modelo 3D dinâmico de mão e punho e um sistema de reconhecimento de gestos no desenvolvimento de uma prótese transradial virtual, visando sua aplicação no treinamento de amputados, para a geração de padrões de contração consistentes e repetitivas para o comando de próteses.

Materiais e métodos

Pensando que o objetivo é modelar uma prótese transradial realista, a multiplataforma *open source Blender*, foi considerada a melhor opção por ser um programa de fácil acesso que possibilita a criação de uma figura humana, e que permite o reconhecimento de sinais externos.

Na prática, modelos humanos virtuais são compostos por diversas camadas, a do esqueleto, a dos músculos e a da pele, cada uma responsável por uma função corporal, como, por exemplo, a camada do esqueleto que é composta, geralmente, por uma representação aramada com um grau de liberdade em suas juntas rotacionais [2,6].

Os gestos que seriam reconhecidos por sEMG foram replicados no *Blender*. Os movimentos definidos foram: mão aberta, preensão cilíndrica, mão relaxada, apontando, pressão lateral e pinça.

O comando para a reprodução do movimento vem do sistema de reconhecimento de padrões.

A braçadeira *Myo Gesture Control Armband System* da *ThalmicLabs*, uma empresa Canadense, (Figura 1) possui um sistema integrado que incorpora 8 canais com eletrodos de superfície, circuito de pré-processamento, aquisição e transmissão dos dados de sEMG, e foi utilizada nesse projeto para a captação dos sinais durante a realização dos gestos especificados anteriormente. Os dados de sEMG, são retornados como `uint_8` sem unidade para cada um dos canais, representando um nível de ativação e não se traduz em unidades de millivolts (mV) ou microvolts (μV). O `uint_8` representa um número inteiro de 0 a 255, que é transmitido por *bluetooth* a uma taxa de 200 Hz.



Figura 1 - *Myo Gesture Control Armband*.

Foi criada uma interface gráfica para o controle da aquisição de dados relacionada aos gestos especificados (Figura 2), visando um treinamento off-line inicial.

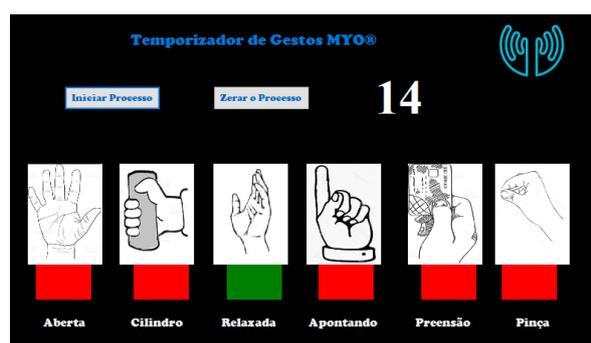


Figura 2. Interface Gráfica para controle da aquisição de dados.

O protocolo de teste foi aprovado em comitê de ética em pesquisa e os voluntários, após receberem as informações sobre os procedimentos, assinaram o termo de consentimento livre e esclarecido.

A aquisição de dados foi realizada com 10 voluntários, entre 16 e 53 anos, sem nenhum tipo de deficiência física e/ou neurológica. Os

voluntários permaneceram sentados, com o braço flexionado a 90° e com o *Myo* posicionado na parte superior do antebraço.

O comando para a execução do gesto corresponde à indicação em verde na interface, com duração de 5s. O gesto mão relaxada foi intercalado a cada execução de gesto válido, e não fez parte do sistema de reconhecimento.

Durante o processamento, foram selecionados os 3s centrais, correspondentes à fase estática de cada gesto, que foram subdivididos em janelas de 300ms sem sobreposição.

A característica utilizada foi a potência do sinal. Já a normalização foi feita a partir da padronização dos canais, para cada amostra, obtendo-se o maior valor de potência, dentre os oito eletrodos do *Myo*, e dividindo todos por esse valor.

Para o processo de reconhecimento, foram utilizados 2 classificadores, sendo o k – vizinhos mais próximos (kNN) e uma rede neural (ANN). No primeiro caso, foi configurado $k=7$ vizinhos mais próximos, e no segundo, uma rede neural simples, com 8 neurônios de entrada e 5 de saída, e uma camada escondida com 10 neurônios e função sigmoid. Os dados foram divididos em dois grupos, sendo 70% para treinamento e 30% para validação e teste, sendo adotada a técnica de validação cruzada.

Resultados

O modelo 3D criado foi composto pela camada das articulações, que representam os ossos, e a camada externa, que representa a pele, como pode ser observado na Figura 3.

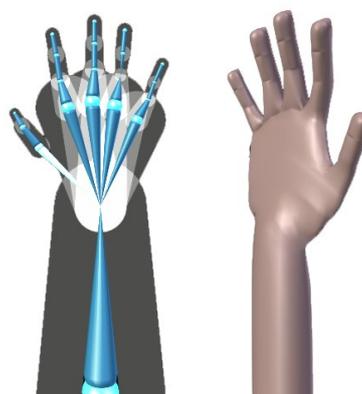


Figura 3. Articulação e Modelo finalizado.

A partir dos testes realizados conseguiu-se reproduzir os gestos escolhidos; iniciando com o comando correspondente ao gesto de interesse, um script em Python, rotaciona as juntas do

modelo em X, Y ou Z até resultar na pose desejada (Figura 4). O gesto mão relaxada é utilizado quando um sinal de sEMG abaixo de um limiar pré-estabelecido é detectado, enquanto os outros 5 gestos recebem comando através do sistema de reconhecimento e classificação de gestos.

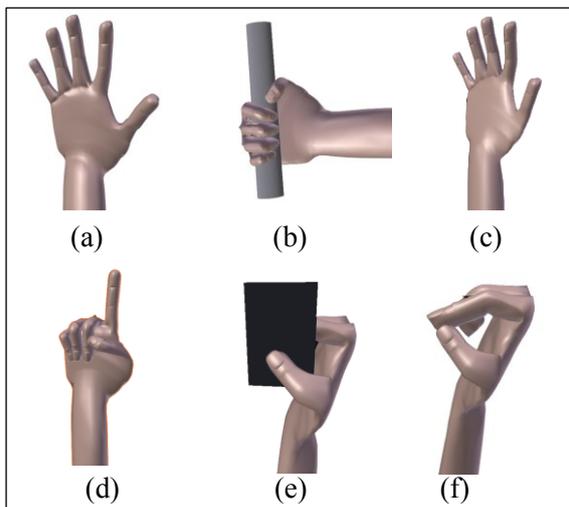


Figura 4. Gestos: (a) Mão Aberta, (b) Preensão Cilíndrica, (c) Mão Relaxada, (d) Apontando, (e) Pressão Lateral e (f) Pinça.

Os resultados obtidos com os algoritmos de reconhecimento e classificação podem ser vistos na Tabela 1. Os testes consideraram cada voluntário individualmente (V_i), obtendo-se a média das acurácias ($AccM$), bem como considerando-se todos os voluntários fazendo parte de um único grupo e obtendo-se uma única acurácia geral ($AccG$).

Tabela 1 – Resultados de Classificação (Acurácia %)

	kNN	ANN
V_1	82	85
V_2	76	76
V_3	91	76
V_4	69	76
V_5	73	93
V_6	100	91
V_7	78	78
V_8	69	80
V_9	67	83
V_{10}	85	96
AccM	79	83,4
AccG	79	73

Foram feitas comparações entre as taxas de acerto obtidas pelos dois classificadores aplicando-se o teste t-student pareado, utilizando-se um nível de significância 5%. Não há diferença

estatisticamente significativa entre os resultados, considerando as taxas de acerto para cada um dos voluntários ($p < 0,2335$) e as taxas de acerto para cada um dos gestos (Figura 5), considerando os voluntários agrupados ($p < 0,6467$).

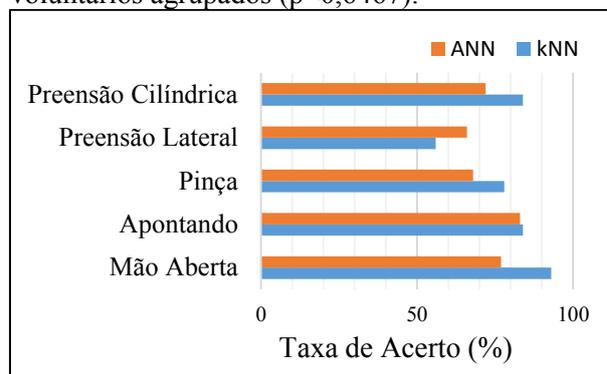


Figura 5 – Taxas de Acerto para cada um dos gestos definidos, para cada uma das técnicas de classificação.

Discussão e Conclusões

O modelo virtual proposto aqui foi capaz de reproduzir gestos comumente utilizados em atividades do cotidiano, sendo os mesmos a serem adotados em uma prótese real. O seu uso, integrado a um sistema de reconhecimento de gestos por sEMG, propiciará maior interação com um usuário de prótese em potencial, durante a fase de treinamento.

Sabe-se que o sEMG apresenta uma variabilidade que é inerente ao ser humano. Duas execuções nunca são exatamente iguais. Por este motivo, técnicas de reconhecimento de padrões são utilizadas, afim de lidar com essa variabilidade. Adicionalmente, a introdução de uma realimentação visual do movimento desejado, através da chamada prótese virtual, pode contribuir positivamente para a obtenção de contrações musculares mais consistentes e repetitivas, de forma que o resultado final seja um aumento da acurácia do sistema [1,2].

Deve-se levar em consideração que o *Myo armband*, apesar de ser um sistema de mercado dedicado a interações humano computador baseado em sEMG, com aplicações em jogos, realidade aumentada, sistemas de mídia, não fornece o *raw signal* com frequência ideal para processamento. O que é disponibilizado é um valor inteiro de 0 a 255, sem nenhuma expressão relacionada à tensão, com frequência de transmissão de 200 Hz. Além disso, não há nenhum ajuste externo de sinal, os eletrodos não são adesivos, e a disposição deles é sempre circular. Apenas um ajuste mecânico ao redor do braço é permitido garantindo um bom contato. O

número de canais, maior do que o comumente utilizado nas próteses comerciais, é necessário devido à disposição e ao número de gestos que se pretende reconhecer. Contudo, a Universidade Johns Hopkins, em 2016, juntamente com a Thalmic labs mostraram a viabilidade de controle de uma prótese para amputação transumeral usando dois kits do *Myo armband* [9].

Quanto ao sistema de classificação, nota-se que as taxas obtidas individualmente, foram, em sua maioria, superiores às obtidas quando os voluntários foram agrupados. Devido à variabilidade dos dados, e singularidade na execução dos gestos, este resultado já era esperado. Contudo, apesar da rede neural obter os melhores resultados individualmente, não houve diferenças estatisticamente significativas. Considerando as semelhanças entre os gestos escolhidos, como mostraram os resultados da figura 5, as taxas de acerto da Tabela 1 foram da mesma ordem de grandeza ou superiores às obtidas em outros trabalhos [5, 7, 8].

Apesar da simplicidade e maior rapidez de treinamento do algoritmo kNN, o custo de processamento da rede neural pode compensar. Levando-se em conta que é esperado uma diminuição das taxas de acerto para um amputado, e que a taxa de acerto pode definir a aceitabilidade da prótese pelo usuário, a busca por taxas mais altas é sempre um objetivo.

Em [1], foram utilizados entre 8 e 12 eletrodos adesivos, posicionados de maneira circular, porém em duas fileiras. Para cada janela de 150ms de sEMG foram extraídas 4 características no domínio do tempo, classificadas com a aplicação da Análise de Discriminantes Lineares (LDA), obtendo-se para o reconhecimento de 6 padrões de preensão 69% de acurácia.

Pontos a serem melhorados correspondem ao tempo de resposta, uma vez que 300ms é considerado um tempo limítrofe para acionamento de uma prótese; aumento da acurácia, principalmente para o caso de usuários amputados, os quais ainda não foram testados. E por fim, pode-se pensar, em um segundo momento, aumentar o número de gestos, incluindo movimentos de punho.

Agradecimentos

Ao Centro Universitário da FEI pelo apoio e suporte ao desenvolvimento do projeto.

Referências

[1] Li, G.; Schltz, AE, Kuiken, TA. Quantifying Pattern Recognition – Based Myoelectric Control

of Multifunctional Transradial Prostheses. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2010; 18(2):185-192.

[2] Engeberg, ED. A Physiological Basis for Control of a Prosthetic Hand. Biomedical Signal Processing and Control; 2013; 8(1):6-15.

Doi 10.1016/j.bspc.2012.06.003

[3] Ottobock - SensorHand Speed e VariPlus Speed [internet]. 2013. Disponível em:

<http://www.ottobock.com.br/prosthetics/membros-superiores/visão-geral-das-soluções/sistemas-mioelétricos/>

[4] TouchBionics - I-Limb Mobile apps (2017). Disponível em:

<http://www.touchbionics.com/products/i-limb-mobile-apps>

[5] CASTRO, MCF, Arjunan, SP, KUMAR, DK. Selection of suitable hand gestures for reliable myoelectric human computer interface. BioMedical Engineering OnLine; 2015; 14:30.

Doi 10.1186/s12938-015-0025-5

[6] Maurel, W. 3D Modeling of the Human Upper Limb Including the biomechanics of joints, muscles and soft tissues. [PhD Thesis], École Polytechnique Fédérale de Lausanne, Suíça, 1999.

[7] Momen, K, Krishnan, S, Chau, T. Real-Time Classification of Forearm Electromyographic Signals Corresponding to User-Selected Intentional Movements for Multifunction Prosthesis Control. IEEE Transactions on neural Systems and Rehabilitation Engineering. 2007; 15(4):535-542.

Doi 10.1109/TNSRE.2007.908376

[8] Cipriani, C et al. Online Myoelectric Control of a Dexterous Hand Prosthesis by Transradial Amputees. IEEE Transactions on neural Systems and Rehabilitation Engineering. 2011; 19(3):260-270. Doi 10.1109/TNSRE.2011.2108667

[9] Dawes, T. Thalmic Labs Myo armband allows amputee to control prosthetic limb. Cantech Letter. 2016. Disponível em:

<https://www.cantechletter.com/2016/01/thalmic-labs-myo-armband-allows-amputee-to-control-prosthetic-limb/>