

DESENVOLVIMENTO DE UM ESTIMADOR PARA O MOVIMENTO DO COTOVELO HUMANO BASEADO EM INTELIGÊNCIA ARTIFICIAL E SINAIS ELETROMIOGRÁFICOS

R. S. Figueiredo, rafael.figueiredo1@hotmail.com¹
C. S. Carvalho, cristiano.carvalho@cefet-rj.com¹
E. Y. Veslin, elkinveslin@ufrj.br²
F. L. Silva, fabricio.silva@cefet-rj.br¹
G. A. P. Campos, guilherme.campos@cefet-rj.br¹
L. S. C. Raptopoulos, luciano.raptopoulos@cefet-rj.br¹
L. Bevilacqua, bevilacqua@coc.ufrj.br²
M. S. Dutra, max@mecanica.coppe.ufrj.br²
W. S. Andrade, waltencir.andrade@cefet-rj.br¹

¹NUPEM/CEFET-RJ – Núcleo de Pesquisa em Mecatrônica do Centro Federal de Educação Tecnológica Celso Suckow da Fonseca, Estr. de Adrianópolis 1317, CEP 26041-271, Nova Iguaçu, RJ, Brasil

²Universidade Federal do Rio de Janeiro, Av. Horácio Macedo 2030, Centro de Tecnologia, Bloco G, sala 101, Cidade Universitária, CEP 21941-914, Rio de Janeiro, RJ, Brasil

Resumo: Neste trabalho é apresentado o projeto e desenvolvimento de um estimador baseado em inteligência artificial para identificação de sinais eletromiográficos (sinais EMG) e consequente análise cinemática do cotovelo humano. O estimador proposto será utilizado em um mecanismo assistivo de um grau de liberdade, representando o movimento de flexão/extensão do cotovelo humano. Para a captura dos sinais EMG foi utilizado um sistema comercial BTS FreeEMG 1000, que faz uso de eletrodos de superfície sem fio com frequência de aquisição igual a 1000 Hz. Os sinais brutos, após filtrados, serviram de base para o treinamento de uma rede neural artificial (RNA) do tipo Perceptron de Múltiplas Camadas (Multilayer Perceptron - MLP). Os resultados obtidos indicam uma boa correlação entre o movimento real realizado, medido através de eletrogoniômetros de eixos gêmeos, e o comportamento cinemático produzido pela rede neural projetada. Dessa maneira, os resultados permitem concluir pela boa aplicabilidade do estimador projetado.

Palavras-chave: inteligência artificial, redes neurais artificiais, sinais EMG, mecanismos assistivos.

1. INTRODUÇÃO

Um dispositivo de tecnologia assistiva é qualquer item, parte de equipamento ou sistema, adquirido comercialmente, modificado ou customizado, usado para aumentar, manter ou aprimorar as capacidades funcionais de indivíduos com deficiências (Alper and Rahariniirina, 2006). Assim, mecanismos assistivos são dispositivos que têm por finalidade auxiliar a movimentação das pessoas que possuem algum tipo de limitação sensorial ou motora, possibilitando que estas se reintrodzam tanto no ambiente produtivo quanto às atividades comuns de convívio social. No que tange à limitação motora, as próteses são dispositivos que tem como função a substituição total ou parcial de um membro. Contudo, em virtude de não-linearidades inerentes à cinemática e à dinâmica desses dispositivos, a realização do controle deste tipo de dispositivo apresenta elevado custo computacional.

Sinais de origem biológica, como os sinais eletromiográficos (sinais EMG), vem sendo usados no controle de próteses robóticas, no intuito de tornar os movimentos e a experiência tão naturais quanto possível. Porém, esses sinais também apresentam não-linearidades, dificultando sua utilização em sistemas de controle mais simples.

Os sistemas inteligentes são capazes de realizar o mapeamento de espaços de entrada e de saída altamente complexos e não-lineares, sendo assim uma ótima escolha para lidar com os processos envolvidos no presente estudo.

Neste trabalho é apresentado o projeto e simulação de um estimador para o movimento do cotovelo humano baseado em inteligência artificial e sinais eletromiográficos, sendo toda a análise desenvolvida no domínio do tempo. Uma análise baseada no domínio da frequência fará parte de um trabalho futuro.

2. DESENVOLVIMENTO

Neurologicamente, uma unidade motora (UM) consiste de uma junção sináptica na raiz ventral da coluna vertebral, um axônio motor e uma placa motora nas fibras musculares (Winter, 2009). Quando é preciso realizar um movimento, as uni-

dades motoras de uma região muscular são recrutadas. De acordo com o Princípio do Tamanho (*Size Principle*), as UMs são recrutadas sequencialmente, começando pela menor unidade motora e terminando com a maior delas (Henneman, 1968).

Cada UM recrutada produz um potencial de ação, que é um sinal de natureza elétrica. A frequência desses sinais, chamada de taxa de disparo, aumenta de acordo com o aumento da tensão muscular produzida. Quando a taxa de disparo do potencial de ação da primeira UM recrutada atinge um limiar, a unidade motora seguinte é recrutada. Essa sequência é exemplificada na Fig. 1. Um sinal EMG é o somatório algébrico do potencial de ação de todas as unidades motoras recrutadas.




Figura 1: Sequência de disparo de uma UM. Adaptado (Winter, 2009).

A aquisição dos sinais EMG foi realizada por meio da eletromiografia de superfície (*surface electromyography* - sEMG), técnica não invasiva que consiste no posicionamento de eletrodos na superfície da pele. Os sinais mensurados por meio dessa técnica, porém, necessitam passar por um tratamento de amplificação e de filtragem (De Luca *et al.*, 2010). O equipamento utilizado para aquisição foi o BTS FreeEMG 1000, da BTS Bioengineering, que já realiza todo esse tratamento no sinal. O protocolo de captura adotado é ilustrado na Fig. 2.




Figura 2: Diagrama representando o protocolo de captura dos sinais EMG.

O movimento contemplado pelo estudo é o de flexão/extensão do cotovelo. Por meio de um eletrogoniômetro de eixos gêmeos, foi mensurado o histórico do ângulo formado pelo braço e pelo antebraço, enquanto um sensor EMG foi posicionado no bíceps e outro no tríceps, de modo que os sinais produzidos por esses músculos sejam medidos, e deles sejam extraídas as características relacionadas àquele movimento. Os sensores que acompanham o equipamento são ilustrados na Fig. 3.



Figura 3: Sensores que acompanham o BTS FreeEMG 1000; (a) sensor EMG e (b) eletrogoniômetro. Imagens extraídas do manual de usuário do equipamento.

2.1 Processamento dos Sinais

Além de ruídos externos e de artefatos de movimento, a eletricidade estática acumulada pela superfície da pele é um outro tipo de ruído que afeta os sinais eletromiográficos. A solução adotada para este problema foi incluir no procedimento um eletrodo para capturar um sinal que servisse como referência para os demais. Esse terceiro sensor foi posicionado fora da cadeia cinemática do movimento estudado, localizando-se na lateral esquerda do tronco, próximo à cintura. Exemplos de sinais capturados pelos três sensores do protocolo são exibidos na Fig. 4. Como primeira etapa de processamento, o sinal de referência foi subtraído dos outros dois sinais.




Figura 4: Sinais mioelétricos capturados durante uma sequência de flexões e extensões do cotovelo.

Em seguida, os sinais foram processados no domínio do tempo, começando pela obtenção do módulo de cada sinal. Determinar o módulo de um sinal significa calcular a raiz quadrada de seu valor instantâneo elevado ao quadrado, como apresentado na Eq. 1, para um sinal variante no tempo $s(t)$.

$$|s(t)| = \sqrt{s(t)^2} \quad (1)$$

Assim, a parte negativa dos sinais é rebatida em torno do eixo das abcissas (que representa o tempo) e todos os sinais utilizados no estudo passam a apresentar apenas valores instantâneos positivos, como pode ser visto na Fig. 5. Posteriormente, a envoltória de cada um dos sinais foi obtida por meio de um filtro passa-baixas, como apresentado na Fig. 6.




Figura 5: Módulo dos sinais EMG.




Figura 6: Envoltória dos sinais EMG exibidos na Fig. 5.

2.2 Regressão por meio de uma Rede Neural Artificial (RNA)

As envoltórias dos sinais mioelétricos são utilizadas, juntamente com o histórico do ângulo do cotovelo, no treinamento de uma rede neural. Foi escolhido utilizar esse tipo de sistema por sua capacidade de mapear e atuar em sistemas que apresentam não-linearidades (Haykin, 1999).

Os sensores EMG possuem frequência de amostragem igual a 1000 Hz , enquanto a do eletrogoniômetro é igual a 100 Hz . Ou seja, o primeiro tipo de sensor é dez vezes mais rápido que o segundo. Isso significa que uma leitura do eletrogoniômetro é feita enquanto cada sensor EMG realiza dez medições, conforme ilustrado na Fig. 7. Dessa forma, decidiu-se criar amostras de treinamento compostas por dez amostras de cada envoltória dos sinais EMG do protocolo de captura e uma medição feita pelo eletrogoniômetro. Em outras palavras, uma amostra de treinamento é composta por vinte valores de entrada e um valor de saída, fazendo com que a rede neural possua vinte entradas e uma única saída.




Figura 7: Representação do processo de amostragem realizado pelos sensores EMG e pelo eletrogoniômetro.

Arquiteturas básicas de redes neurais, como a Perceptron ou a Adaline, são capazes somente de resolver problemas de separação linear (Da Silva *et al.*, 2010). Em virtude disso, a arquitetura escolhida para o estágio atual do estudo foi a Perceptron de Múltiplas Camadas (em inglês, *Multilayer Perceptron* - MLP). Redes do tipo MLP são poderosas por apresentarem profundidade, isto é, por possuírem pelo menos uma camada oculta de neurônios. As camadas ocultas (ou intermediárias) são assim chamadas por não serem "vistas" em termos de entrada e saída da rede.

Treinar uma rede neural significa realizar um mapeamento do espaço de saída no espaço de entrada por meio do ajuste dos pesos sinápticos dos neurônios da rede de modo que a mesma realize determinada tarefa de maneira satisfatória. No processo de treinamento, valores instantâneos das envoltórias dos sinais EMG fizeram o papel de padrão de entrada, enquanto o ângulo real do cotovelo serviu como alvo do treinamento.

Depois do treinamento, a RNA foi colocada em modo de operação e novos dados foram apresentados à ela, para que

fosse realizada a validação do treinamento. Nesse momento, a RNA passou a receber somente padrões de entrada, e sua resposta a esses padrões foi comparada com os valores reais do ângulo do cotovelo.

A raiz quadrada do erro quadrático médio (*root mean squared error - RMSE*) foi adotada como parâmetro de desempenho, para avaliar tanto o resultado do processo de treinamento quanto o número de neurônios adequado para compor a camada oculta da rede. Essa escolha foi feita com base no fato de que o erro médio quadrático (*mean squared error - MSE*) é utilizado como indicador padrão de desempenho pelo *toolbox* de redes neurais do MatLab®. A vantagem do RMSE em relação ao MSE reside no fato de que o primeiro apresenta a mesma unidade da resposta da RNA. Sendo k o número total de padrões de entrada apresentados à rede, d_i o i -ésimo valor de saída desejado como resposta e y_i a i -ésima resposta produzida pela RNA em modo de operação, o RMSE é dado pela Eq. 2.

$$RMSE = \sqrt{\frac{1}{k} \sum_{i=1}^k (d_i - y_i)^2} \quad (2)$$

Modificando o número de neurônios na camada oculta para, em seguida, treinar a rede e colocá-la em modo de operação, foi possível levantar curvas que relacionam o desempenho da rede e o número de neurônios na camada oculta. O processo foi repetido trinta vezes para cada número n de neurônios na camada oculta. Na Figura 8 é mostrada a curva do menor RMSE obtido em função do número de neurônios. Também foi levantada a curva do valor médio do RMSE e o desvio padrão correspondente em função da quantidade de neurônios na camada oculta, como é ilustrado no gráfico da Fig. 9.




Figura 8: Gráfico do RMSE em função do número de neurônios da camada oculta.




Figura 9: Gráfico da média do RMSE em função do número de neurônios da camada oculta.

A partir dos gráficos das Fig. 8 e 9, é possível perceber que embora uma rede que possua um único neurônio na camada oculta apresente a menor média para o RMSE, essa configuração não atinge um desempenho tão bom quanto o de uma rede que possui dois ou três neurônios em sua camada oculta. Diante disso, a composição da rede neural no atual estágio do estudo é representada na Fig. 10 e detalhada na Tabela 1.




Figura 10: Esquema da RNA utilizada no estudo.

Tabela 1: Principais informações da rede neural utilizada no estudo.

Número de Camadas Ocultas	1
Número de Neurônios na Camada Oculta	2
Número de Neurônios na Camada de Saída	1
Função de Ativação dos Neurônios da Camada Oculta	Tangente Hiperbólica Sigmoidal
Função de Ativação dos Neurônios da Camada de Saída	Linear

Ainda sobre a camada oculta, decidiu-se utilizar a função tangente hiperbólica sigmoidal por ser uma função não-linear cuja derivada é calculada de maneira simples. Isso significa que é capaz de mapear o espaço de trabalho altamente não-linear do estudo proposto de maneira mais eficiente que uma função linear o faria, sem apresentar elevado custo computacional.

3. RESULTADOS

Os testes conduzidos até o momento com a rede neural processando os sinais tratados no domínio do tempo retornaram o resultado ilustrado na Fig. 11, para o qual a raiz quadrada do erro quadrático médio entre o movimento real e o movimento estimado pela RNA é igual a 3,4343°.




Figura 11: Gráfico do ângulo do cotovelo humano em função do tempo para uma série de flexões e extensões.

O comportamento do sinal estimado nas regiões de mudança de sentido de movimento foi aprimorado em relação aos

primeiros testes conduzidos, tendo sido alcançada a suavização dessas regiões, correspondendo à morfologia natural do movimento.

É possível perceber através do gráfico da Fig. 12, que representa o ângulo estimado em função do ângulo medido, um resultado semelhante ao de uma função identidade para os três ciclos de flexão e extensão ilustrados na Fig. 11, conforme era desejado.




Figura 12: Gráfico do ângulo estimado em função do ângulo medido.

4. CONCLUSÕES

Neste trabalho foi apresentado o projeto de um estimador cinemático para o movimento de flexão e extensão do cotovelo humano, com base em redes neurais artificiais. A análise dos resultados obtidos mostra que a RNA projetada relaciona o comportamento cinemático real e aquele estimado para a articulação do cotovelo com erro igual a $3,4343^\circ$, indicando que a metodologia proposta tem aplicação no campo das tecnologias assistivas inteligentes (neuromecatrônica). Entretanto, é fundamental que próteses robóticas sejam altamente precisas, exigindo que sejam conduzidos mais testes para alcançar um desempenho ainda melhor por parte do estimador. Para isso, o próximo passo consiste em realizar testes com os sinais mioelétricos no domínio da frequência, afim de comparar os resultados com aqueles obtidos até o momento e determinar qual metodologia é mais adequada à tarefa.

Outra adição que será feita ao trabalho é a criação de uma base de dados a partir de sinais eletromiográficos de um grupo de voluntários, com o intuito de fornecer à rede neural informações generalizadas relacionadas ao movimento estudado. Dessa maneira, espera-se que a RNA fique melhor preparada para estimar o movimento independente do indivíduo que utilize o sistema.

5. AGRADECIMENTOS

Este trabalho foi parcialmente apoiado pelo CNPq, FINEP, DIPPG/CEFET-RJ e FAPERJ.

6. REFERÊNCIAS

- Alper, S. and Raharinirina, S., 2006. "Assistive technology for individuals with disabilities: A review and synthesis of the literature". *Journal of Special Education Technology*, Vol. 21, No. 2, pp. 47–64.
- Da Silva, I.N., Spatti, D.H. and Flauzino, R.A., 2010. "Redes neurais artificiais para engenharia e ciências aplicadas". São Paulo: Artliber, pp. 33–111.
- De Luca, C.J., Gilmore, L.D., Kuznetsov, M. and Roy, S.H., 2010. "Filtering the surface emg signal: Movement artifact and baseline noise contamination". *Journal of biomechanics*, Vol. 43, No. 8, pp. 1573–1579.
- Haykin, S., 1999. *Neural networks a comprehensive introduction*. Prentice Hall, New Jersey.
- Henneman, E., 1968. "Organization of the spinal cord". *Medical physiology*, Vol. 12, pp. 1717–32.
- Winter, D.A., 2009. *Biomechanics and motor control of human movement*. John Wiley & Sons.

7. RESPONSABILIDADE AUTORAIS

Os autores são os únicos responsáveis pelo conteúdo deste trabalho.

DEVELOPMENT OF AN ESTIMATOR FOR THE MOVEMENT OF THE HUMAN ELBOW BASED ON ARTIFICIAL INTELLIGENCE AND ELECTROMYOGRAPHIC SIGNALS

R. S. Figueiredo, rafael.figueiredo1@hotmail.com¹

C. S. Carvalho, cristiano.carvalho@cefet-rj.com¹

E. Y. Veslin, elkinveslin@ufrj.br²

F. L. Silva, fabricio.silva@cefet-rj.br¹

G. A. P. Campos, guilherme.campos@cefet-rj.br¹

L. S. C. Raptopoulos, luciano.raptopoulos@cefet-rj.br¹

L. Bevilacqua, bevilacqua@coc.ufrj.br²

M. S. Dutra, max@mecanica.coppe.ufrj.br²

W. S. Andrade, waltencir.andrade@cefet-rj.br¹

¹NUPEM/CEFET-RJ – Mechatronics Research Center of the Federal Center for Technological Education Celso Suckow da Fonseca, 1317 Estr. de Adrianópolis, Nova Iguaçu, RJ 26041-271, Brazil

²Universidade Federal do Rio de Janeiro, Av. Horácio Macedo 2030, Center for Technology, Bloco G, sala 101, Cidade Universitária, Rio de Janeiro, RJ 21941-914, Brazil

Abstract: *In this work, the design and development of an estimator based on artificial intelligence is presented. The proposed estimator shall be used for the identification of electromyographic signals (EMG signals) and the consequent kinematic analysis of the human elbow. It is intended to use the obtained estimator in a one-degree-of-freedom assistive mechanism that corresponds to the flexion/extension movement of the elbow. In order to capture the EMG signals, the commercial system BTS FreeEMG 1000 was used. The system works with wireless surface electrodes with sampling rate equal to 1000 Hz. The raw signals, after filtering, were used as the basis for training a Multilayer Perceptron (MLP) artificial neural network (ANN). The obtained results indicate a good correlation between the actual movement performed, measured using twin axis electrogoniometers, and the kinematic behavior produced by the projected neural network. Therefore, the results allow concluding that the designed estimator presents a good applicability.*

Keywords: *artificial intelligence, artificial neural networks, EMG signals, assistive mechanisms.*