

Aplicação de Neuro-Fuzzy na Predição de Forças em Sistemas Biomecânicos

Marcelo Elias de Oliveira, Departamento de Engenharia Mecânica e de Materiais, Instituto Militar de Engenharia, e-mail: marcelo_eo@gmx.de, home-page: <http://www.marcelo.110mb.com>

Luciano Luporini Menegaldo, Departamento de Engenharia Mecânica e de Materiais, Instituto Militar de Engenharia, e-mail: lmeneg@ime.eb.br, home-page: <http://lmeneg.tripod.com>

Introdução

Um dos desafios tecnológicos no desenvolvimento de próteses mioelétricas está relacionado ao desenvolvimento de sistemas capazes de relacionar a intenção do movimento com as contrações musculares [1]. Tais contrações são medidas através da eletromiografia de superfície (EMG), que fornece a atividade elétrica em uma população de fibras musculares e que podem ser relacionadas com o nível de força muscular [1].

Os sinais de EMG são susceptíveis a incertezas associadas a diversos fatores, como a colocação dos eletrodos, artefatos elétricos etc.

Deste modo, deseja-se obter um modelo matemático e computacional robusto capaz de adaptar-se às variações internas do sistema biomecânico, do *setup* experimental, assim como de incorporar características como reflexos naturais.

Este trabalho tem como objetivo principal propor um modelo Neuro-Fuzzy baseado em aprendizagem supervisionada. O modelo será capaz de mapear forças planares, resultantes de contrações de músculos dos membros superiores de sujeitos saudáveis, em função dos níveis de atividade eletromiográfica (EMG).

Sistemas Neuro-Fuzzy

Os sistemas Neuro-Fuzzy podem ser considerados aproximadores universais de funções [3,4]. A abordagem Neuro-Fuzzy na modelagem e identificação de sistemas consiste na aplicação de um algoritmo de aprendizagem (*Fuzzy error backpropagation*) e na especificação de parâmetros apropriados do modelo, tais como funções de pertinência e base de regras [3,4]. Estas especificações podem ser realizadas a partir de um conhecimento preexistente do comportamento do sistema, por aprendizagem ou pela combinação de ambos [3,4].

As Redes Neurais Artificiais (RNAs) são modelos matemáticos e computacionais inspirados no sistema nervoso, nos quais parâmetros são determinados através da experiência [2]. A aprendizagem em RNAs ocorre através de alterações dos pesos sinápticos que estão distribuídos na arquitetura do modelo. Tais modelos são considerados Black-Box, pois a distributividade dos pesos sinápticos faz com que, em arquiteturas complexas, seja impossível uma interpretação física do sistema [2].

A integração de Sistemas Lógicos Difusos e RNAs proporciona modelos híbridos considerados Gray-Box, que por sua vez possuem estruturas conexionistas e habilidade de extrair informações do sistema através das funções de pertinência e do conjunto de regras Fuzzy definidas [3,4].

Metodologia

O experimento, que foi realizado no Instituto Max-Planck for Human Cognitive and Brain Sciences - Sensomotorische Koordination Lab, Munique, consistiu primeiramente na eliminação de graus de liberdade indesejados. O sujeito foi fixado a um assento rígido com o pulso devidamente imobilizado. Em seguida solicitou-se que girasse a manivela *ad libitum*, em cujo centro de rotação foi instalado um motor DC, capaz de gerar um campo de viscosidade (fig. 1).

Foram realizadas aquisições de dados referentes a atividades eletromiográficas de alguns músculos do membro superior direito (fig. 2) e forças (F_x e F_y) através de uma célula de carga multiaxial instalada na haste de manipulação do sistema mecânico. Utilizou-se uma frequência de amostragem de 1Kh e os dados foram coletados durante 30s usando RTAI-Linux (Real Time Application Interface for Linux), com um sistema de aquisição de dados da National Instruments (PCI – 16bits).

Os sinais de EMG foram processados da seguinte maneira: filtragem analógica passa-

banda 30-300 Hz, retificação de onda completa e filtragem digital passa baixa a 5 Hz para obtenção do envelope linear. As forças obtidas foram normalizadas entre -1 e 1.

O modelo Neuro-Fuzzy foi definido através do pacote NEFPROX (*Neuro-Fuzzy Function Approximation*) [5]. Em seguida utilizou-se os vinte primeiros segundos dos dados coletados para o treinamento e os últimos dez segundos para validação da capacidade de generalização do modelo Neuro-Fuzzy.




Figura 1: Configuração do experimento




Figura 2: Músculos anteriores e posteriores dos membros superiores

Modelo Neuro-Fuzzy proposto

O modelo Neuro-Fuzzy proposto consiste da seguinte estrutura:

- Número de entradas: 6 (músculos utilizados)
- Número de funções de pertinência para cada unidade de entrada: 7
- Tipo de função de pertinência para as unidades de entrada: Gaussiana
- Número de regras: 7 (IF-THEN)
- Número de saídas: 2 (F_x e F_y)
- Tipo de função de pertinência para as unidades de saída: Gaussiana

O treinamento foi realizado no modo Batch e os critérios de parada adotados foram: 104 épocas atingindo um erro de treinamento: 0.835218 e erro de generalização: 0.677547

Resultados

As figuras 3, 4, 5 e 6 mostram a validação e a predição das forças F_x e F_y . As linhas em vermelho representam o sistema real e as linhas em verde a resposta do modelo Neuro-Fuzzy proposto.

Os erros médios quadráticos para validação das forças F_x e F_y foram 0.016499 e

0.0081273. Para a predição os erros quadráticos médios foram 0.072988 e 0.027308.




Figura 3: Fx Validação




Figura 4: Fx Predição




Figura 5: Fy Validação




Figura 6: Fy Predição

Conclusões

Observando as figuras de 3 a 6 podemos concluir que o modelo Neuro-Fuzzy proposto nesse trabalho foi capaz de identificar qualitativamente o sistema biomecânico. Essa identificação poderia ser melhorada através de alterações das funções de pertinência, número de partições Fuzzy e número de regras utilizados no modelo.

Os resultados mostram que um modelo Neuro-Fuzzy com topologia e pré-processamentos dos sinais de entrada/saída adequados é capaz de prever forças resultantes da atuação de um conjunto de músculos do membro superior a partir da atividade eletromiográfica.

Referências bibliográficas

- [1] Koike, Y., and Kawato, M. (1995): 'Estimation of dynamic joint torques and trajectory formation from surface electromyography signals using a neural network model', Biol. Cybern., 73, pp. 291-300
- [2] Haykin, S.: 'Neural Networks, A Comprehensive Foundation'. Macmillan College Publishing Company, New York, 1994.
- [3] Nauck, D.: 'A Fuzzy Perceptron as a Generic Model for Neuro-Fuzzy Approaches'. Paper of the 2nd German GI-Workshop "Fuzzy-Systeme'94 in Munich, Oct. '94"
- [4] Nauck, D. and Kruse, R.: 'Neuro-Fuzzy Systems for Function Approximation'. Paper of the 4. International Workshop Fuzzy-Neuro Systems 1997 in Soest
- [5] <http://fuzzy.cs.uni-magdeburg.de/nefprox/>