

# ALGORITMO DE ESTIMAÇÃO DO ÂNGULO DO JOELHO PARA CONTROLE MIOELÉTRICO

A. L. Delis, F. A. O. Nascimento, J. L. A. Carvalho, A. F. da Rocha e G. A. Borges

Departamento de Engenharia Elétrica/Universidade de Brasília, Brasília-DF, Brasil

e-mail: lopez\_delis@yahoo.com

**Abstract:** This work presents the implementation of an algorithm for myoelectric control of knee prostheses. An algorithm extracts information from two electromyographic (EMG) channels and one electrogoniometer channel. This information is processed through three stages: (1) feature extraction utilizing auto-regressive model and histogram, (2) feature projection using self organizing maps (SOM), and (3) pattern classification using a Levenberg-Marquadt neural network. The Davies-Bouldin index, which measures cluster separation, is used for evaluating the algorithm. The results of our preliminary experiments are presented.

**Keywords:** Electromyographic signals, prosthesis control, feature projection, neural networks.

## Introdução

O sinal mioelétrico pode ser utilizado de forma eficaz para o controle de próteses mecânicas [1]. Essa técnica, chamada controle mioelétrico, pode ser bastante útil em indivíduos com amputações ou membros congenitamente deficientes. A Figura 1 apresenta os componentes principais de um controlador mioelétrico baseado em reconhecimento de padrões. Os sinais eletromiográficos (EMG) são coletados por eletrodos de superfície localizados na pele, sobre o músculo. O sinal proveniente dos eletrodos de superfície são pré-amplificados, para diferenciar os pequenos sinais de interesse e posteriormente serem amplificados, filtrados e digitalizados. Finalmente, a informação se transfere ao controlador mioelétrico [1]. No processo de projeto e implementação de um controlador mioelétrico, a precisão do sistema é essencial para uma realização correta da intenção do usuário. Tal precisão é um fator importante no desenvolvimento de controladores multifuncionais e pode ser melhorada extraindo mais informação a partir do estado dos músculos e adotando um classificador que seja capaz de aperfeiçoar esta informação. O controlador deve ser capaz de aprender os padrões de ativação musculares que são usados de forma natural para os movimentos. O controlador precisa de robustez contra as condições de variação durante a operação. O tempo de resposta não pode criar demoras que sejam perceptíveis ao usuário. Dado o requisito de tempo real, o tempo de processamento e de

geração dos comandos de controle deve ser menor ou igual a 300 ms.

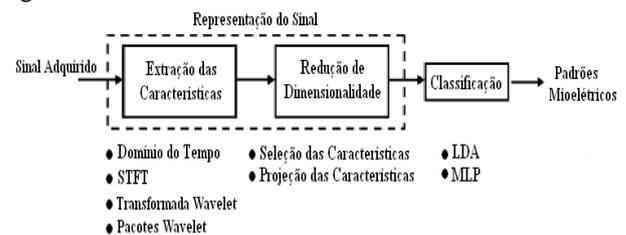


Figura 1: Sistema de controle mioelétrico baseado em reconhecimento de padrões.

Com a utilização de sistemas multi-sensoriais mioelétricos com o objetivo de melhorar a precisão e classificação nos processos de extração e classificação dos padrões, a quantidade de informação redundante no espaço característico nos vetores de entrada na rede aumenta. Isto faz com que o tempo de aprendizagem da rede aumente substancialmente e seja necessário inserir um estágio de projeção de características, com o objetivo de reduzir a dimensionalidade do vetor de entrada [2].

Este trabalho apresenta os resultados preliminares do projeto de um algoritmo para a estimação do ângulo do joelho de um controlador mioelétrico baseado em técnicas de reconhecimentos de padrões. Na próxima seção, apresenta-se uma síntese do conteúdo teórico que envolve os diferentes estágios do controlador mioelétrico proposto. Posteriormente, apresenta-se a metodologia experimental utilizada para a implementação do algoritmo, e uma descrição do método utilizado para a avaliação quantitativa dos resultados. A seguir, faz-se a discussão dos resultados obtidos efetuando uma comparação preliminar com outro algoritmo utilizado na estimação do ângulo [4] e com recomendações para sua otimização.

## Algoritmo de controle mioelétrico

Apresentar o sinal mioelétrico diretamente a um classificador não é prático, devido à dimensão e às características aleatórias do mesmo. É necessário que o sinal seja representado por um vetor de dimensões reduzidas, que se denomina vetor característico. O sucesso do reconhecimento de padrões depende diretamente da correta e eficiente extração de

características do sinal. O algoritmo proposto apresenta três estágios para a extração e classificação de padrões. O primeiro estágio consiste na combinação de vetores característicos obtidos a partir de análises no domínio do tempo e da frequência. Um segundo bloco implementa a redução do espaço característico, o que permite incrementar o número de sensores de EMG sem aumentar a complexidade da rede neural e o tempo de aprendizagem. O último estágio tem como função a estimação do ângulo do joelho.

Dada a natureza estocástica do sinal mioelétrico, esta pode ser considerada como uma série temporal e modelada como uma combinação linear de seus valores passados e presentes. Portanto, o modelo auto-regressivo é uma estrutura conveniente para a identificação de modelos, especialmente quando a velocidade computacional e o tempo de resposta são importantes, sendo este o caso da classificação de padrões mioelétricos. Os parâmetros auto-regressivos (coeficientes) contêm informação sobre o processo da contração muscular. Os coeficientes são obtidos através do método dos mínimos quadrados recursivo (*recursive least squares*, ou RLS) com um fator de esquecimento. O método baseia-se no fato de que as informações de maior importância são aquelas mais próximas à amostra atual no ciclo de iteração. Os parâmetros calculados recursivamente [3] são apresentados nas equações (1), (2) e (3).

$$\hat{\eta}_k = \hat{\eta}_{k-1} + L_k [y_k - \varphi_k^T \hat{\eta}_{k-1}] \quad (1)$$

$$P_k = \left[ P_{k-1} - \frac{P_{k-1} \varphi_k \varphi_k^T P_{k-1}}{\lambda_k \varphi_k^T P_{k-1} \varphi_k} \right] \frac{1}{\lambda_k} \quad (2)$$

$$L_k = \frac{P_{k-1} \varphi_k}{\lambda_k \varphi_k^T P_{k-1} \varphi_k} \quad (3)$$

onde  $\hat{\eta}_k$  são os vetores coeficientes que são estimados no tempo discreto  $k$ ;  $\varphi_k$  são os coeficientes auto-regressivos e  $\lambda_k$  é o fator de esquecimento. Os coeficientes estimados no instante  $k$  podem ser interpretados como características do sinal EMG dentro do intervalo de tempo determinado pelo fator de esquecimento. Portanto, podem ser utilizados para determinar o deslocamento angular que o sujeito deseja impor na prótese [4]. Os coeficientes obtidos compõem um vetor para o processo de projeção de características.

De acordo com Hargrove *et al.* [5], uma configuração funcional e eficiente consiste em uma combinação de vetores característicos no domínio do tempo com coeficientes auto-regressivos. Esta configuração apresenta alta precisão de classificação, e é computacionalmente eficiente, facilitando sua implementação em sistemas embarcados, além de ser mais robusta a possíveis deslocamentos dos eletrodos de superfície [5]. É o caso da combinação de vetores auto-regressivos com os obtidos a partir do histograma do EMG. O histograma de EMG é uma extensão do *Zero Crossing* e a *Amplitude de Willison* [6]. Dado que o sinal mioelétrico alcança níveis relativamente altos durante o processo de contração (comparado à linha de

base), os vetores obtidos a partir do histograma podem ser usados como uma medida de informação sobre a frequência com a qual o sinal de EMG alcança cada nível de amplitude. A implementação utilizada neste trabalho consistiu em estabelecer uma faixa simétrica de amplitude sobre a linha de base e subdividir a mesma em vários níveis, calculando desta forma a frequência com a qual o sinal de EMG cai dentro das diferentes faixas de amplitude. Finalmente, no processo de extração de características, os vetores obtidos a partir dos coeficientes auto-regressivos e do histograma de EMG são concatenados.

Para reduzir a dimensão do espaço característico dos vetores no processo de classificação de padrões em uma rede neural supervisionada, um estágio de projeção de características é usado, através de uma rede neural não supervisionada, com a utilização do *Self-Organizing Map* (SOM). Assim, os grupos de vetores obtidos por cada canal de EMG usando-se o modelo auto-regressivo e o histograma podem ser transformados em vetores de duas dimensões. Além da vantagem na redução da dimensão do espaço de entrada, o SOM pode reduzir ruído, absorver grandes variações que acontecem nos vetores característicos originais, e reduzir o tempo de treinamento da rede supervisionada. O SOM pode encontrar um neurônio vencedor num mapa de duas dimensões para representar os padrões originais (multidimensionais). Para encontrar o neurônio vencedor, quatro passos devem ser implementados de acordo com a regra de aprendizagem do SOM [2].

**Passo 1:** Escolher valores aleatórios para os vetores dos pesos iniciais  $W_j(0)$ .

**Passo 2:** Encontrar o neurônio vencedor  $y_c$  no passo do tempo  $t$  (*Similarity Matching*), usando o critério de distância Euclidiana mínima:

$$y_c = \arg \min \|x(t) - W_j(t)\|, j = 1, 2, \dots, t \quad (4)$$

**Passo 3:** Modificar os vetores dos pesos sinápticos de todos os neurônios, utilizando a seguinte regra de atualização:

$$W_j(t+1) = W_j(t) + \eta(t) h_{j,y_c}(t) [x(t) - W_j(t)] \quad (5)$$

onde  $\eta(t)$  é a razão de aprendizagem e  $h_{j,y_c}(t)$  é a função de vizinhança centrada ao redor do neurônio vencedor.  $\eta(t)$  e  $h_{j,y_c}(t)$  são variados dinamicamente durante a fase de aprendizagem para obter resultados ótimos.

**Passo 4:** Voltar ao passo 2 até que nenhuma mudança aconteça no mapa característico.

Cada canal de EMG apresenta seus vetores característicos à entrada do SOM, e a saída é uma coordenada de duas dimensões, referente aos eixos  $x$  e  $y$  de uma rede topológica, o que constitui a entrada na rede supervisionada para a classificação de padrões.

As redes neurais multicamadas tem sido aplicadas com êxito em vários problemas não-lineares de diversos

domínios. O método utilizado neste artigo é a aplicação de um algoritmo de mínimos quadrados não-linear para o treinamento por lotes do perceptron multicamada, chamado algoritmo *Levenberg-Marquadt* (LM) [7]. O LM pode ser considerado uma modificação do método *Gauss-Newton*, e é utilizado para a computação da matriz Jacobiana. Os detalhes do algoritmo são apresentados em [7]. Este algoritmo é muito eficiente quando se treinam redes que possuem uma centena de pesos, o que compensa sua elevada complexidade computacional.

### Metodologia experimental

Para efetuar o teste e a comparação entre os algoritmos, um conjunto de dados foi capturado em um sujeito saudável, utilizando um sistema de instrumentação de captura de EMG de quatro canais em configuração bipolar e um canal de eletrogoniometria. A frequência de amostragem utilizada para a digitalização dos dados foi de 1744.25 Hz. O sistema transmite os dados adquiridos pelo barramento RS23C para o computador em modo *on-line*. Um *software* de visualização e pré-processamento permite gerar os arquivos de dados para que a classificação de padrões seja realizada a seguir, em modo *off-line*, no *software Matlab*. Como apresentado na Figura 2, as medições de EMG foram feitas com dois canais de eletrodos (em configuração bipolar) localizados nos músculos antagonistas, relacionados com os movimentos de flexão e extensão do joelho. Foram realizadas 10 medições formadas por dois conjuntos de sinais de treinamento e validação, adquiridos para diferentes velocidades de marcha (uma velocidade para cada medição) com uma duração de 10 segundos, o que forma o conjunto dos dados para o processo de treinamento e validação dos padrões mioelétricos.

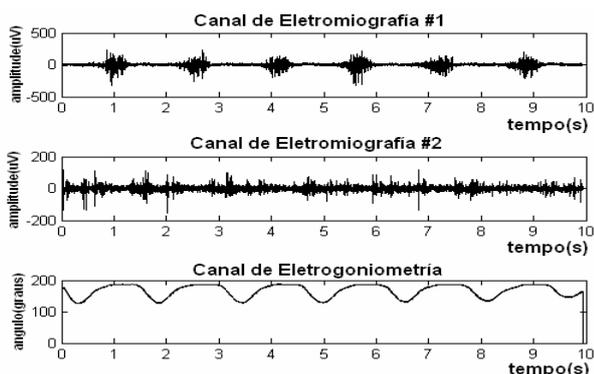


Figura 2: Sinais de EMG adquiridos em músculos antagonistas: Canal de EMG #1 (músculo do reto femoral), Canal de EMG #2 (músculo semitendinoso), Canal de Eletrogoniometria (medição do deslocamento angular no joelho).

Com base no critério de *Akaike* [3], que propõe minimizar a entropia ou a distancia de informação entre o modelo e o sistema real, concluiu-se que um modelo auto-regressivo de quarta a sexta ordem é

suficientemente eficiente para representar o sinal [3,8]. A ordem do modelo auto-regressivo utilizada foi 6, com fator de esquecimento de **0.995**. Para cada canal de EMG, um vetor de entrada de seis coeficientes é obtido a partir dos coeficientes auto-regressivos, concatenando-se a eles o vetor (nove coeficientes) obtido a partir do histograma no qual a faixa de amplitude sobre a linha de base foi subdividido em nove segmentos. Finalmente, um vetor com 15 componentes característicos para cada canal representa a entrada na rede SOM. A saída da rede SOM consiste em uma matriz de 10 x 10, com 100 neurônios em sua estrutura de interconexão. A razão da aprendizagem inicial é **0.9**. Para um vetor de entrada de 15 elementos, um vetor de duas coordenadas será obtido como saída da rede SOM, e utilizado como entrada na rede LM. A rede LM usa três camadas com quatro nós de entrada na primeira camada, seis na segunda e uma camada de saída que representa o ângulo estimado. A Figura 3 apresenta um diagrama geral em blocos do algoritmo para o controlador mioelétrico.

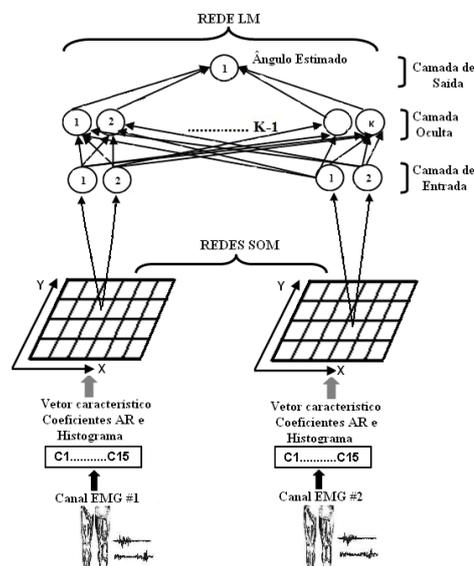


Figura 3: Diagrama esquemático do algoritmo.

### Metodologia de análise quantitativa dos resultados

Para avaliar a quantificação do espaço característico e efetuar uma comparação quanto ao desempenho com respeito à referência [4], o método *Davies-Bouldin* (DB) foi utilizado. Este método fornece uma medida da separação dos clusters, e requer o cálculo da similaridade dos clusters baseada na expressão [6]:

$$R_{ij} = \frac{(S_i + S_j)}{D_{ij}} \quad (6)$$

onde  $S_i$  e  $S_j$  são as dispersões dos *clusters*  $i$  e  $j$  respectivamente, e  $D_{ij}$  é a distancia entre seus valores médios. A dispersão de um *cluster* é definida como:

$$S_i = \left\{ \frac{1}{N_i} \sum_{j=1}^{N_i} (y_i - m_i)^T (y_j - m_i) \right\}^{1/2} \quad y_j \in C_i \quad (7)$$

onde  $N_i$  é o número de *clusters*  $C_i$ ,  $y_i$  é o vetor padrão de entrada, e  $m_i$  é o vetor da média do *cluster*  $i$ . A função de distância entre dois *clusters* pode ser obtida a partir da distância Euclidiana:

$$D_{ij} = \{(m_i - m_j)^T (m_i - m_j)\}^{1/2} \quad (8)$$

O índice DB é obtido promediando o pior caso de separação de cada *cluster* com respeito aos demais, da seguinte forma:

$$DB = \frac{1}{K} \sum_{i=1}^K \max_{i \neq j} (R_{ij}) \quad (9)$$

onde  $K$  é o número de *clusters*. O índice reporta o grau de sobreposição do *cluster* com os vizinhos mais próximos. Baixos valores do índice DB significam alto grau de separação entre os *clusters*.

## Resultados

Este trabalho apresenta o estado atual de desenvolvimento de um algoritmo para o controle mioelétrico de uma prótese ativa de perna, para estimação do ângulo do joelho. No processo experimental, os resultados obtidos foram considerados satisfatórios. A Figura 4 apresenta os resultados de treino e validação da estimativa do ângulo de dobradura do joelho, comparadas aos valores medidos pelo eletrogoniômetro. Os resultados estimados foram, de forma geral, bastante próximos aos valores medidos.

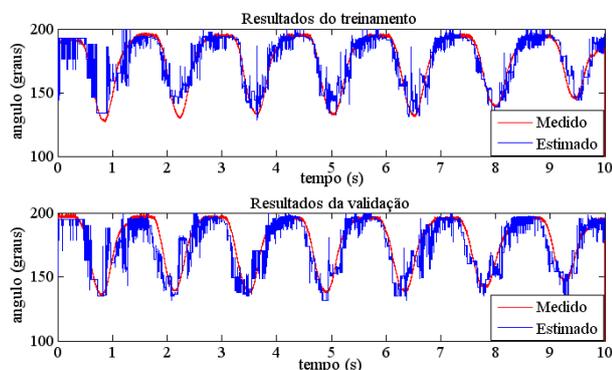


Figura 4: Resultados dos processos de treino e validação de uma captura de dados de EMG.

## Comparação com outras técnicas

Uma comparação preliminar foi realizada a partir da implementação do algoritmo utilizado na referência [4] e o algoritmo proposto neste artigo. Tais algoritmos apresentam um estágio de arquitetura comum no controlador mioelétrico, mas o algoritmo proposto incorpora o histograma de EMG para extração de características e a rede SOM como estágio de redução de dimensionalidade. A comparação foi baseada no cálculo da taxa de erro e o critério *Davies Bouldin*.

Ambos indicadores foram promediados nas 10 medições efetuadas no sujeito. Os resultados obtidos

com o algoritmo proposto foram superiores aos obtidos em [4] (Tabela 1). Futuros esforços visarão reduzir o tempo de execução do algoritmo durante o processo de estimação do ângulo.

Tabela 1: Índices de avaliação dos algoritmos.

Critério	Referencia [4]	Algoritmo proposto
Taxa de Erro	7.33% ± 2.60	6.15% ± 1.57
<i>Davies Bouldin</i>	0.37 ± 0.17	0.0291 ± 0.0031

## Agradecimentos

Agradecemos ao CNPq e a CAPEs pelo apoio financeiro para o desenvolvimento do trabalho.

## Referências

- [1] Mohammadreza, A. O., Huosheng, H. (2007) "Myoelectric Control System – A survey" *Journal Biomedical Signal Processing and Control*, p. 275-294.
- [2] Haykin, S. (1999) "Neural Networks: A Comprehensive Foundation", New Jersey: Prentice Hall.
- [3] Ljung, L. (1987) "Linear System Identification", Prentice-Hall, Inc: Englewood Cliffs.
- [4] Ferreira, R. U., da Rocha, A.F., Casão, Jr C. A., Borges, G. A., Nascimento, F. A. O., Veneziano, W. H. (2005) "Reconhecimento de Padrões de Sinais de EMG para Controle de Prótese de Perna" In: *Proceedings of the XI Congresso Brasileiro de Biomecânica*, Brasil.
- [5] Hargrove, L., Englehart, K., Hudgins, B. (2008) "A training strategy to reduce classification degradation due to electrode displacements in pattern recognition based myoelectric control" *Journal Biomedical Signal Processing and Control*, vol 3 p 175-180.
- [6] Kermani, M. Z., Wheeler, B. C., Badie, K., Hashemi, R. M. (1995) "EMG Feature Evaluation for Movement Control of Upper Extremity Prostheses" *Journal IEEE Transactions on Rehabilitation Engineering*, vol 3.
- [7] Hagan, M. T., Menhaj, M. B. (1994) "Training feedforward networks with the Marquardt Algorithm" *Journal IEEE Transactions Neural Network*, vol 5, p 989-993.
- [8] Doershuk, P. C., Gustafon, D. E., Wilsky, A. S. (1983) "Upper extremity limb function discrimination using EMG signal analysis" *Journal IEEE Transactions Biomedical Engineering*, vol 30, p 18-29.