

# VARIAÇÃO DA ORDEM AUTORREGRESSIVA COM A FORÇA DE CONTRAÇÃO MUSCULAR E A DURAÇÃO DO ELETROMIOGRAMA

C. Romaro\*, C. Itiki\*

\*Laboratório de Engenharia Biomédica, Escola Politécnica da Universidade de São Paulo, São Paulo, Brasil  
e-mail: cecilia.romaro@gmail.com

**Resumo:** O presente trabalho estuda, para sinais de eletromiografia de agulha gravados sob as mesmas condições experimentais, como varia o número ótimo de coeficientes autorregressivos com o comprimento das épocas e com a força de contração muscular concomitantemente. O estudo foi realizado tendo como base sinais de 10%, 25%, 50% e 80% da máxima contração voluntária e tendo épocas de 500ms, 250ms, 100ms, 50ms e 25ms de seis indivíduos normais. Desta forma, uma função densidade de probabilidade é sugerida para a ordem do modelo autorregressivo que melhor descreva o sinal de eletromiografia obtido a uma “força de contração” específica e que tenha uma “duração da época” definida.

**Palavras-chave:** eletromiografia de agulha, modelo autorregressivo, contração muscular.

**Abstract:** *This paper studies how the optimal number of autoregressive coefficients changes with the epoch length and the muscle contraction force concomitantly for needle electromyography signals recorded under the same experimental conditions. The study was conducted on signals from six normal individuals with 10%, 25%, 50% and 80% of the maximum voluntary contraction and epoch lengths of 500ms, 250ms, 100ms, 50ms and 25ms. Thus, a probability density function is suggested for the order of the autoregressive model that best describes the electromyographic signal obtained at a specific "contraction force" and has a defined "epoch length".*

**Keywords:** needle electromyography, autoregressive model, muscle contraction.

## Introdução

Os sinais de eletromiografia têm sido usados em vários estudos, incluindo a classificação de movimentos da mão, o deslocamento de eletrodos durante movimentos, a fadiga muscular e o diagnóstico de doenças neuromusculares [1] – [8].

A modelagem destes sinais como saídas de sistemas autorregressivos é pertinente uma vez que parâmetros deste modelo (coeficientes autorregressivos e cepstrais) têm fornecido informações úteis que auxiliam o diagnóstico clínico [4] – [8]. No entanto, a utilização dos sistemas autorregressivos esbarra na dúvida quanto ao número de parâmetros necessários para representar adequadamente os sinais de eletromiografia de agulha.

Aplicações como reconhecimento de movimentos utilizam ordem 4 e duração de 50 a 300ms [9] – [10]. Para o caso de fadiga muscular utilizam-se ordens de 12 a 30 com 500 a 512ms de duração [11] – [13]. No entanto, na modelagem autorregressiva de sinais de eletromiografia, visando o diagnóstico, a duração das épocas tem sido escolhida numa gama muito vasta, de 25,6 milissegundos a 500,0 milissegundos. Além disso, a ordem do modelo autorregressivo também tem sido selecionada numa faixa ampla, de 12 a 20. Essas variações conjuntamente com outras diferenças metodológicas resultaram em taxas globais de classificação diagnóstica que oscilaram entre 47,5% e 87,5% [6] – [7].

Esses resultados da literatura indicam que a escolha do número de coeficientes do modelo autorregressivo é uma questão importante e que pode ser influenciada pela duração da época do sinal de eletromiografia. Nenhum trabalho anterior estudou como varia o número ótimo de coeficientes autorregressivos com o comprimento das épocas e com a força de contração muscular concomitantemente, para sinais de eletromiografia de agulha gravados sob as mesmas condições experimentais. Visando esclarecer essa questão, o presente trabalho se propõe a determinar o número de coeficientes do modelo autorregressivo que melhor representaria o sinal de eletromiografia de agulha, para sinais de 500ms divididos em épocas (de 250ms, 100ms, 50ms e 25ms) e captados para várias porcentagens (de 10%, 25%, 50% e 80%) da máxima contração voluntária de sujeitos normais.

## Materiais e métodos

**Sinais de eletromiografia** – Os sinais de eletromiografia foram obtidos de um banco de dados gerado na Duke University (EUA), cedido para esta pesquisa e descrito em trabalhos anteriores [8]. Os sinais selecionados haviam sido captados de sete localizações diferentes do músculo bíceps braquial de seis indivíduos normais, para contrações correspondentes a 10%, 25%, 50% e 80% da máxima contração voluntária (MCV). Eles haviam sido amplificados de 100 a 1000 vezes e filtrados por um passa-baixas com frequência de corte de 10kHz [14].

Os sinais analógicos haviam sido convertidos para digitais por um conversor analógico-digital de doze bits à taxa de amostragem de vinte e cinco mil amostras por segundo. Os sinais selecionados haviam sido considerados estacionários na média e variância pelo teste de sequências (*run test*) [14].

No presente trabalho, foram selecionados sete sinais de 500ms para cada força de contração muscular por indivíduo. Esses sinais foram posteriormente subdivididos em épocas de 250ms, 100ms, 50ms e 25ms.

**Modelagem autorregressiva** – Cada época foi modelada como a saída  $y(t)$  de um sistema autorregressivo, descrito por [15]

$$y(t) = -a_1 y(t-1) - a_2 y(t-2) \dots - a_n y(t-n) + e(t) \quad (1)$$

em que  $y(t)$  é o sinal de eletromiografia na saída do sistema,  $e(t)$  é o ruído branco desconhecido na entrada do sistema,  $t$  é o número da amostra,  $n$  é a ordem do modelo e  $a_k$  correspondem aos coeficientes do modelo, para  $k = 1, 2, \dots, n$ .

Os coeficientes do modelo e a variância do sinal de entrada foram calculados pela função *arx.m* do Matlab, que minimizou o erro quadrático médio por meio da fatoração QR [16].

Para uma dada época, a variância dos sinais estimados de entrada, que se modifica com o número  $(n+1)$  de coeficientes selecionado, foi usada no critério de escolha de ordem. A ordem  $n$  do modelo foi variada entre 1 e 100, para a seleção daquela considerada “ótima”, ou seja, a que minimizasse o critério de escolha.

**Escolha da ordem ótima** – A ordem ótima de modelo auto regressivo foi calculada para os sinais eletromiográficos dos 6 indivíduos normais.

O critério de comprimento mínimo de descrição (MDL, do inglês *Minimum Description Length*) consiste de uma função que pondera o comprimento  $N$  da época e a ordem  $n$  do modelo, de acordo com a relação de Rissanen [17]

$$MDL(n) = N \times \ln[\sigma_n^2] + n \times \ln[N], \quad (2)$$

em que  $\sigma_n^2$  é a variância do sinal estimado da entrada do sistema,  $N$  é o número total de amostras e  $n$  é a ordem do modelo autorregressivo. As épocas têm  $N=625, 1250, 2500, 6250$  e  $12500$  amostras para as respectivas durações de 25ms, 50ms, 100ms, 250ms e 500ms.

A ordem ótima do modelo autorregressivo foi encontrada para cada uma das épocas. A partir destes dados iniciou-se o estudo de como a ordem ótima variava com a duração da época e com a força de contração voluntária.

**Teste Estatístico** – Para rejeitar a hipótese de igualdade das distribuições, o teste de Friedman, teste estatístico não paramétrico, foi aplicado tendo como fator a MCV. Os valores de probabilidades obtidos

foram  $9.3 \times 10^{-19}$ ,  $7.6 \times 10^{-17}$ ,  $6.4 \times 10^{-13}$ ,  $6.5 \times 10^{-13}$  e  $1.1 \times 10^{-9}$  respectivamente para as épocas de 25ms, 50ms, 100ms, 250ms e 500ms. Sendo todos abaixo de 0.05, concluiu-se que há diferença significativa entre as distribuições resultante da variação da força de contração.

**Histogramas normalizados** – Cada par %MCV e duração da época foi considerado um sistema autorregressivo.

O histograma de ordens ótimas foi gerado para cada sistema e então normalizado, pois o número de sinais eram diferentes para durações de épocas diferentes.

**Ajuste de funções densidade de probabilidade** – Várias funções foram ajustadas ao histograma de ordens ótimas. Dentre elas, as funções Gaussiana, LogNormal e Gama apresentaram os resultados mais representativos e, por isso, são apresentados neste trabalho.

A função densidade de probabilidade para a distribuição Gaussiana é dada por:

$$y = f(x | \mu, \sigma) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (3)$$

em que  $\mu$  é a média e  $\sigma$  é o desvio padrão. A distribuição normal ajustada foi a que apresentou a mesma média  $\mu$  e o mesmo desvio padrão  $\sigma$  do respectivo histograma normalizado.

A função densidade de probabilidade para a distribuição LogNormal é dada por:

$$y = f(x | \mu, \sigma) = \frac{1}{x\sigma\sqrt{2\pi}} e^{-\frac{(\ln x - \mu)^2}{2\sigma^2}} \quad (4)$$

em que  $\mu$  é a média e  $\sigma$  é o desvio padrão da distribuição normal da função  $\log(X)$ . A distribuição LogNormal escolhida foi a que apresentou a mesma média  $\mu$  e o mesmo desvio padrão  $\sigma$  do conjunto de logaritmos das respectivas ordens ótimas.

A função densidade de probabilidade para a distribuição Gama é dada por:

$$y = f(x | a, b) = \frac{1}{b^a \Gamma(a)} x^{a-1} e^{-\frac{x}{b}} \quad (5)$$

em que  $a$  é o parâmetro de forma,  $b$  é o parâmetro de escala e  $\Gamma(a)$  é calculada por:

$$\Gamma(a) = \int_0^{\infty} e^{-t} t^{a-1} dt. \quad (6)$$

O ajuste da distribuição Gama foi obtido por máxima verossimilhança (MLE).

As diversas funções densidade de probabilidade foram ajustadas para cada histograma normalizado das ordens ótimas dos modelos AR. Os ajustes foram obtidos pelas funções fornecidas pelo Matlab: *normfit.m*, *lognfit.m* e *gamfit.m*. A distribuição escolhida foi a que apresentou o menor erro quadrático médio quando comparada com o histograma normalizado.

## Resultados

Os resultados estão exibidos na Figura 1. As cores representam os valores dos histogramas normalizados. Azul escuro representa valores baixos (próximos de zero) e vermelho escuro, valores altos do histograma.

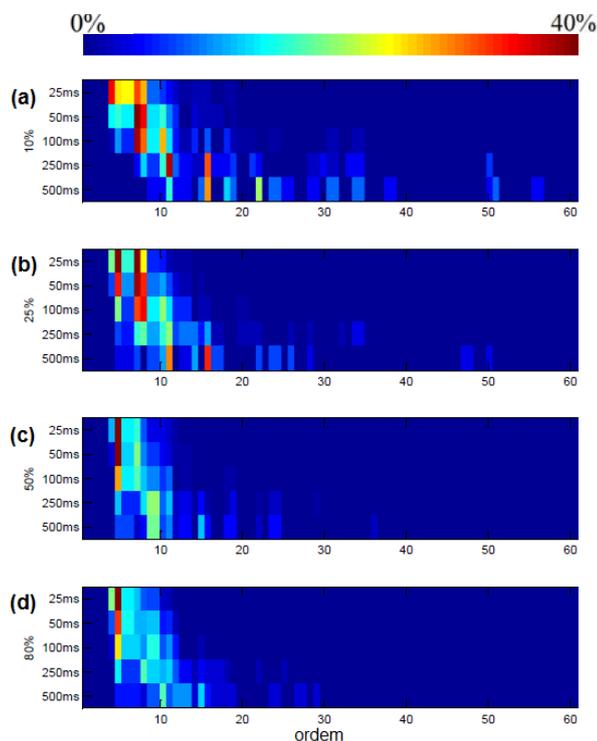


Figura 1: Histogramas normalizados da ordem ótima para (a) 10%MCV, (b) 25%MCV, (c) 50%MCV e (d) 80%MCV. As cores indicam a porcentagem de épocas que forneceram a ordem indicada no eixo horizontal.

Na Figura 1, é possível notar que a ordem ótima do modelo AR tende a diminuir com o aumento da força de contração voluntária. Além disso, observa-se que a ordem ótima do modelo AR tende a aumentar para épocas maiores.

A Tabela 1 apresenta a distribuição que melhor se adequou a cada par de duração de época e força de contração.

Tabela 1: Melhor distribuição densidade de probabilidade para diferentes durações de época e contrações voluntárias.

época/MCV	10%	25%	50%	80%
025ms	LogNormal	LogNormal	LogNormal	LogNormal
050ms	LogNormal	Gama	LogNormal	LogNormal
100ms	LogNormal	Gama	LogNormal	LogNormal
250ms	LogNormal	LogNormal	LogNormal	Gama
500ms	LogNormal	LogNormal	LogNormal	Gama

As distribuições Gama e LogNormal foram as que apresentaram os menores erros quadráticos, tendo ora a Gama resultado no menor erro quadrático, ora a LogNormal. Quando a LogNormal não apresentou o menor erro quadrático, resultou no segundo menor erro. Ou seja, dentre as três distribuições apresentadas neste artigo, a Gaussiana apresentou-se como a função densidade de probabilidade com os piores ajustes, em todas as vinte combinações de duração de época e de força de contração.

## Discussão

A ativação repetida do motoneurônio resulta em um trem de MUPs (do inglês *Motor Unit Potential*, potencial de ação de unidade motora), típico de contrações musculares fracas. Quando mais de uma unidade motora é ativada, os trens de MUPs podem sobrepor-se e interferir um no outro, resultando no padrão de interferência, característico de contrações musculares médias e fortes. Portanto, o sinal de eletromiografia (EMG) pode consistir de um trem de MUPs ou de um padrão de interferência, dependendo da força de contração muscular.

A diminuição da ordem ótima com o aumento da força de contração indica que os modelos AR são mais apropriados para descrever padrões de interferência do que trens de MUPs. Vale ressaltar que independente de ser um trem de MUPs ou um padrão de interferência, o sinal de EMG foi representado por modelos AR cuja ordem é melhor descrita pela distribuição LogNormal (78% dos casos).

O aumento da ordem ótima com o aumento da época pode ser atribuído a dois fatores sendo eles: o aumento da complexidade do sinal com o aumento da época; o algoritmo de escolha de critério de comprimento mínimo de descrição. O algoritmo pondera o comprimento da época e a ordem do modelo da seguinte forma: Quanto maior for a época maior será o peso ( $N$ ) dado à variância que o peso ( $\log[N]$ ) dado à ordem. Não permite, assim, ordens demasiadamente elevadas para épocas demasiadamente pequenas.

Quanto às funções densidade de probabilidade para a ordem ótima do modelo AR, foram escolhidas a LogNormal e a Gama. A distribuição Gama é uma distribuição da família Pearsoniana de distribuições, que é muito utilizada para modelar o logaritmo da variável. Desta forma fica compreensível porque a distribuição Gama compete em desempenho com a LogNormal, logaritmo da distribuição Normal, neste trabalho. Apesar de amplamente utilizada na literatura, a distribuição Gaussiana foi a que apresentou os piores ajustes, de acordo com os erros quadráticos médios.

### Conclusão

A ordem ótima do modelo AR de sinais de eletromiografia de agulha tende a diminuir com o aumento da força de contração voluntária e aumentar com a duração da época. As distribuições que modelam o logaritmo da ordem apresentam as funções densidade de probabilidade mais apropriadas para representar o número ótimo de coeficientes AR que descrevem os sinais de eletromiografia estudados neste trabalho.

### Agradecimentos

Ao Prof. D. Sanders (Duke University) pelo banco de dados.

### Referências

- [1] Huang H, Xie HB, Guo JY, and Chen HJ, “Ant colony optimization-based feature selection method for surface electromyography signals classification,” *Computers in Biology and Medicine*, vol. 42, no. 1, pp. 30-38, Jan 2012.
- [2] Young AJ, Hargrove LJ, and Kuiken TA, “Improving myoelectric pattern recognition robustness to electrode shift by changing interelectrode distance and electrode configuration,” *IEEE Transactions on Biomedical Engineering*, vol. 59, no. 3, pp. 645-52, Mar 2012.
- [3] Zhang ZG, Liu HT, Chan SC, Luk KD, and Hu Y, “Time-dependent power spectral density estimation of surface electromyography during isometric muscle contraction: methods and comparisons,” *Journal of Electromyography and Kinesiology*, vol. 20, no. 1, pp. 89-101, Feb 2010.
- [4] Fuglsang-Frederiksen A, “Interference EMG analysis,” in *Computer-Aided Electromyography and Expert Systems*, J. E. Desmedt, Ed. Amsterdam: Elsevier Science, 1989, pp. 161-179.
- [5] Berzuini C, Maranzana-Figini M, and L. Bernardinelli, “Effective use of EMG parameters in the assessment of neuromuscular diseases,” *International Journal of Bio-Medical Computing*, vol. 13, pp. 481-499, 1985.
- [6] Inbar GF, Noujaim AE, “On surface EMG spectral characterization and its application to diagnostic classification,” *IEEE Transactions on Biomedical Engineering*, vol. 31, no. 9, pp. 597-694, 1984.
- [7] Pattichis CS and Elia AG, “Autoregressive and cepstral analyses of motor unit action potentials,” *Medical Engineering and Physics*, vol. 21, n. 6-7, pp. 405-419, 1999.
- [8] Itiki C. Epoch length and autoregressive-order selection for electromyography signals. *Proceedings of the 34th Annual International Conference of the IEEE-EMBS*, San Diego, USA, 28 Aug.-1 Sept., pp. 3476-3479, 2012
- [9] Chiang J, Wang Z, M.J. McKeown. “Hidden Markov multivariate autoregressive (HMM-mAR) modeling framework for surface electromyography (sEMG) data,” *Conf. Proc. IEEE Eng. Med. Biol. Soc.*, 2007, pp. 4826-4829, 2007.
- [10] Latwisen A, Patterson PE. “Identification of lower arm motions using the EMG signals of shoulder muscles,” *Med. Eng. Phys.*, vol. 16, no. 2, pp. 113-121, 1994.
- [11] Clancy EA, Farina D, Merletti R. “Cross-comparison of time- and frequency-domain methods for monitoring the myoelectric signal during a cyclic, force-varying, fatiguing hand-grip task,” *J. Electromyogr. Kinesiol.*, vol. 15, no. 3, pp. 256-265, 2005.
- [12] Karlsson S, Yu J. “Estimation of surface electromyogram spectral alteration using reduced-order autoregressive model,” *Med. Biol. Eng. Comput.*, vol. 38, no. 5, pp. 520-527, 2000.
- [13] Paiss O, Inbar GF. “Autoregressive modeling of surface EMG and its spectrum with application to fatigue,” *IEEE Trans. Biomed. Eng.*, vol. 34, no. 10, pp.761-770, 1987.
- [14] Wald A and Wolfowitz J, “Optimum character of the sequential probability ratio test,” *Annals of Mathematical Statistics*, vol. 19, no. 3, pp. 326-339, 1948.
- [15] Kay SM, *Modern Spectral Estimation: Theory and Application*, Englewood Cliffs: Prentice- Hall, 1987, pp. 234-237.
- [16] Ljung L, *System Identification Theory for the User*, 2nd ed. Upper Saddle River, NJ: PTR Prentice Hall, 1999, ch.10.
- [17] Rissanen J, “A universal prior for the integers and estimation by minimum description length,” *The Annals of Statistics*, vol. 11, pp. 417-431, 1983.