

COMPARAÇÃO DE CARACTERÍSTICAS DO SINAL MIOELÉTRICO VISANDO O RECONHECIMENTO DA POSIÇÃO ANGULAR DO BRAÇO

Pedro A. Camargo e Maria Claudia F. Castro

Depto. de Eng. Elétrica / Centro Universitário da FEI, São Bernardo do Campo, Brasil

e-mail: mclaudia@fei.edu.br

Abstract: This paper presents a comparison of myoelectric features for arm flexion/extension movements aiming to distinguish different angular positions of the elbow. The efficiency was measured by the classification rate by using the Regularized Linear Discriminant Analysis, for configurations with 2, 3, 4, 5 and 10 classes. For the first movement, amplitude increased gradually with intermediate breaks, while in the second, cycles of flexion/extension movements were repeated by increasing the total movement amplitude. Samples of myoelectric signal were selected during the static phase of the movement, in 10° step. Ten myoelectric features were extracted and evaluated, both in the time as in the frequency domain. The classification rates, obtained for the first movement, were slightly higher than for the second and the extension phase showed the best results. As the number of classes increases the classification rates decreased, representing higher similarities among classes and discrimination difficulties. The features in frequency domain showed better results mainly the Average Power Spectral Density which obtained 100% of classification for 2 classes (0°-90°) and 57% for 10 classes (all positions with intervals of 10°). In the time domain the best feature was the myoelectric signal envelope that obtained 99% for 2 classes and 51% for 10 classes. These results were attained for the first movement during extension phase.

Palavras-chave: Reconhecimento de Padrões, Análise de Discriminantes Lineares (LDA), Sinal Mioelétrico, Posição angular do braço, Flexão/Extensão.

Introdução

Eletromiografia é o estudo de fenômenos elétricos durante a contração muscular, captando variações da atividade elétrica em função do tempo. Dentre suas diversas aplicações está a possibilidade de criação de próteses e exoesqueletos de membros superiores, que habilitam ações através de uma interface robótica, relacionando padrões de sinais mioelétricos a posições ou a movimentos [1-2].

A extração de características é uma forma de processamento de sinais mioelétricos já tratados, ou seja, devidamente amplificados e filtrados, que resulta em uma nova representação dos dados originais em

função de propriedades específicas. Além disso, como o processamento ocorre geralmente em porções de dados (janelamento), gera uma redução na dimensionalidade do conjunto de dados inicial. Após a extração, os novos dados devem passar por um classificador, que tem como função discriminar os padrões existentes, em cada grupo de dados, e associá-los a uma determinada classe correspondente a uma posição ou movimento [1-4].

O mais comum é a extração de características no domínio do tempo propostas por [5] correspondendo basicamente ao Valor Absoluto Médio (MAV), Cruzamentos com o eixo Zero (ZC), Variações da direção de inclinação e Comprimento de Onda (WL). Adicionalmente a essas características [6-7] propuseram a utilização dos Coeficientes do Modelo Auto-Regressivo (AR), relatando que a utilização conjunta resultou em taxas de classificação superiores. Um estudo de comparação de 12 características pode se encontrado em [8]. Além das características mencionadas, pode-se acrescentar ainda o Valor quadrático médio (RMS), Amplitude de Willison, Frequência Média e Frequência Mediana, entre outras. Usando como classificador o LDA, as características que mais se destacaram foram o WL, MAV, RMS e AR, apresentando taxas de classificação, respectivamente de 94,85%, 88,55%, 88,12% e 86,76%. Já o trabalho de [9], utilizando um conjunto parecido de características, atingiu taxas mais baixas do que estas, para cada característica tratada individualmente, mas quando formou grupos de características obteve taxas de classificação acima de 95%. Em [10] o autor apresenta também um estudo comparativo, mas com um conjunto diferente de características. Ele propõe o uso da Densidade Espectral de Potência (PSD), suas médias (PSD_Av) e momentos (PSD_Mo) em contraste com o cálculo da energia do sinal (SI) em diferentes janelamentos. Neste caso, dependendo do tipo e comprimento do janelamento o melhor resultado foi obtido pelo PSD_Mo ou SI variando desde 62% a 95%.

Dentro deste contexto, esse trabalho apresenta uma comparação de desempenho de diferentes características extraídas dos sinais mioelétricos do bíceps e tríceps, durante movimentos de flexão e extensão do braço, utilizando a LDA Regularizada (RLDA) como classificador, visando à identificação de posições angulares do cotovelo. O trabalho se distingue dos demais mencionados pela utilização de sinal mioelétrico obtido durante posicionamento estático após a execução

de movimentos com baixo nível de contração, em oposição às contrações isométricas com médio nível de contração muscular geralmente utilizada e pela semelhança entre as classes formadas com o aumento do número de posições angulares consideradas, em oposição aos diferentes estados flexão/extensão que constituem as classes como geralmente é aplicado.

Análise de Discriminantes Lineares

A Análise de Discriminantes Lineares (LDA) é um classificador estatístico que obtém uma nova base vetorial sobre a qual projeta os dados originais (1), visando promover a separabilidade de classes, sendo y a matriz resultante da projeção da matriz de dados originais x na base vetorial W_{lda} .

$$y = W_{lda}^T x \quad (1)$$

O método criado por Ronald A. Fisher propõe que a melhor base é aquela que maximiza a relação S_b/S_w , onde S_b é a covariância inter-classes e S_w é a covariância intra-classes. Algumas matrizes S_w podem ser singulares ou próximas da singularidade, e para lidar com essa limitação, a adição de um fator de regularização é um dos métodos adotados (RLDA) [11-12].

Materiais e Métodos

Base de dados – Os dados foram adquiridos através de 2 pares de eletrodos de superfície, localizados na cabeça curta do biceps e na cabeça lateral do tríceps e o eletrodo de referência localizado no punho. O antebraço do voluntário foi apoiado em uma estrutura que permitiu apenas a movimentação horizontal, indicando o ângulo do cotovelo. Participaram dessa pesquisa 7 voluntários, que realizaram duas configurações de movimentos de flexão e extensão do braço, no plano horizontal, sem carga, sendo 3 repetições de cada configuração. Este protocolo foi aprovado por comitê de ética em pesquisa COEP- USJT No 076/2010.

Os sinais foram adquiridos com o equipamento PowerLab 16/4 (AdInstruments), com frequência de aquisição de 1000 Hz. Foram utilizados no pré-processamento filtros analógicos passa faixa entre 10 e 500 Hz e um rejeita 60 Hz.

Na primeira configuração de movimento (MHSC1), a partir da posição de braço estendido 0° , o braço foi flexionado progressivamente de 10° em 10° até 90° , e em seguida estendido até 0° , da mesma forma. No segundo movimento (MHSC2), foram realizadas repetições de ciclos de flexão e extensão, iniciando na posição de 0° , com aumentos de 10° na amplitude de movimento a cada repetição, até atingir uma amplitude máxima de 90° .

Para cada posição angular, durante posicionamento estático com variação de 10° em 10° , foi extraído 1 s de dados, o que pela frequência de aquisição, corresponde a 1000 pontos para cada músculo. Cada um desses períodos foi dividido em 5 amostras, totalizando 15 amos-

tras de dimensão 400 para cada classe, para cada configuração de movimento.

Os dados foram normalizados com a exclusão do valor médio, e em relação ao maior valor, em módulo, de cada músculo, para toda a tabela de dados.

Características – Foram extraídas as seguintes características no domínio do tempo: Envolvimento do sinal (ARV), Valor Quadrático Médio (RMS), Valor Médio Absoluto (MAV), Cruzamentos com o eixo zero (ZC), Comprimento de onda (WL) e Amplitude de Willison (WAMP) e no domínio da frequência foram extraídos: Coeficientes do modelo auto-regressivo (AR), Densidade Espectral de Potência (PSD), Médias da PSD (PSD_Av) e Momentos da PSD (PSD_Mo). Para um detalhamento dessas características pode-se consultar [8,13]. O janelamento foi de 100 dados de largura, com sobreposição de 90%.

RLDA – Nesse trabalho, foram utilizados fatores de regularização de 10^{-9} , 10^{-7} , 10^{-5} , 10^{-3} , 10^{-1} e 0,9, considerando-se o que resultar no maior índice de classificação, em cada caso estudado.

Experimentos – Os testes constituíram na avaliação do efeito de combinações de parâmetros como, configuração de movimento (MHSC1, MHSC2 ou ambos MHSC12), características (RMS, MAV, WL, WAMP, AR, ARV, PSD, PSD_Mo ou PSD_Av) e número de classes, correspondendo ao número de posições angulares consideradas, sendo 2, 3, 4, 5 ou 10.

Para duas classes, foram consideradas as posições angulares 0° e 90° e para três classes as posições 10° , 50° e 90° . As posições angulares 0° , 30° , 60° e 90° formaram a configuração de quatro classes, as posições 10° , 30° , 50° , 70° e 90° formaram a configuração de 5 classes, enquanto a configuração de 10 classes considerou todas as posições. Em relação ao MHSC1, na fase de extensão, a ordem das posições foi inversa à descrita anteriormente.

Resultados

As maiores taxas médias de classificação foram obtidas utilizando-se, no domínio do tempo, a ARV, o RMS e o MAV, e no domínio da frequência, a PSD, a PSD_Av e o PSD_Mo. Comparativamente, as características no domínio da frequência atingiram melhores taxas médias de classificação, e em especial a PSD_Av.

Para o MHSC1, a configuração de movimento que apresenta diferenciação entre flexão e extensão, foi possível observar taxas médias de classificação ligeiramente maiores na fase de extensão, para todas as características e número de classes estudadas, e também um decréscimo das taxas médias de classificação, à medida que o número de classes aumentou (Figuras 1 e 2).

Para 2 classes, a ARV, a PSD, a PSD_Av e o PSD_Mo obtiveram taxas médias acima de 99% de classificação. Para 3 classes os resultados mais significativos ocorreram para a PSD, a PSD_Av e o PSD_Mo atingindo índices médios superiores a 92%. Já

para 4 classes a ARV, a PSD, a PSD_Av e o PSD_Mo atingiram índices médios superiores a 80%, sendo que a PSD_Av, na fase de extensão, atingiu 90% de classificação, e para 5 classes foi a única característica com taxas próximas a 80%. As taxas de classificação considerando 10 classes foram inferiores, ficando no intervalo entre 40% e 60%.

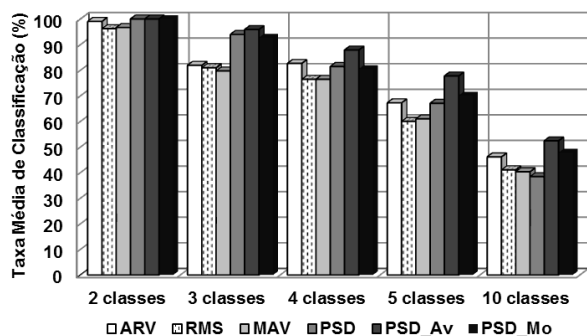


Figura 1 - Taxas médias de classificação para as melhores características no MHSC1 na fase de Flexão.

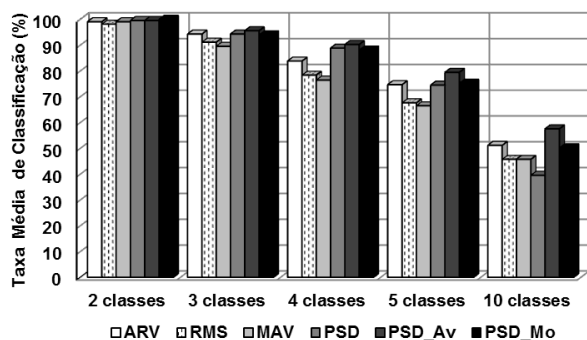


Figura 2 - Taxas médias de classificação para as melhores características no MHSC1 na fase de Extensão.

A Figura 3 mostra os principais resultados obtidos para o MHSC2, apresentando o mesmo padrão geral, descrito para o MHSC1, porém com taxas médias, em sua maioria, ligeiramente inferiores às apresentadas no primeiro caso. Para 2 classes, a ARV, a PSD, a PSD_Av e o PSD_Mo obtiveram taxas médias acima de 96% de classificação. Para 3 classes os resultados mais significativos ocorreram para a PSD e a PSD_Av atingindo índices médios em torno de 91% e para 4 classes 83%. As taxas de classificação para a configuração de 5 classes, para as características no domínio da frequência ficaram entre 70% e 75% enquanto que para 10 classes as taxas ficaram no intervalo próximo de 40% e 50%.

Quando os dois conjuntos de dados, provenientes das duas configurações de movimentos foram consideradas em conjunto, formando a base de dados MHSC12, as taxas de classificação seguiram o mesmo padrão descrito anteriormente, apresentando a mesma ordem de grandeza, porém com valores ligeiramente inferiores (Figura 4). Mas uma nova característica

mereceu destaque; o AR, para a configuração de classes a partir de 4 superou as taxas obtidas pela PSD.




Figura 3 - Taxas médias de classificação para as melhores características no MHSC2.




Figura 4 - Taxas médias de classificação para as melhores características, para os dados de MHSC1 e MHSC2, considerados em conjunto.

Discussão

A proporcionalidade inversa entre taxa de classificação e número de classes pode ser explicada de duas formas: através do método de classificação e através do sinal mioelétrico para cada classe considerada. Em relação à RLDA, o aumento do número de classes significa que um número maior de planos é necessário para separar as classes, diminuindo o espaço representativo de cada uma delas, e aumentando as regiões de interseção. Com isso, a possibilidade de atribuições errôneas aumenta. Já em relação ao sinal mioelétrico, deve-se levar em consideração que os movimentos foram feitos sem carga, com baixo nível de força. Posições próximas, como por exemplo, diferenças de 20° ou 10°, representam níveis de contrações musculares similares, e, portanto, a diferenciação do sinal mioelétrico de cada uma torna-se um fator crítico.

Em [8], apesar do número de classes avaliadas ter sido 6, as posições consideradas foram distintas entre si, representando a abertura e o fechamento da mão, flexão e extensão do punho e flexão e extensão do braço, realizadas com um nível de força médio. Dentre o conjunto de características avaliado, as que mais se

destacaram foram o WL, MAV, RMS e AR, com 94,85%, 88,55%, 88,12% e 86,76% de classificação, respectivamente. Esses resultados estão em discordância com os apresentados aqui, mas as diferenças de configuração do experimento, relacionadas ao nível de força exercida e as classes, devem ser levadas em consideração. A situação em que as posições de flexão/extensão foram consideradas, correspondendo à configuração de 2 classes, obteve taxas superiores a 96% para a maioria das características. Outra distinção foi o WL ter sido, no experimento aqui apresentado, a segunda pior característica, com índices de classificação da ordem de 80%, considerando-se apenas as posições de extensão e flexão (0° e 90°).

Os autores de [4] mostram que em contrações com níveis de força baixo, as taxas de erro são 10% superiores àqueles verificados em sistemas de classificação empregando níveis de força médios. Levando-se isso em consideração, os índices de erro apresentados em [8] seriam compatíveis com a configuração de 4 classes, situação em que as posições angulares diferem em 30° entre si.

Em um experimento trabalhando com sinais ruidosos e procurando avaliar a robustez das características avaliadas [9] só obteve taxas da ordem de 90% a partir da combinação de características. Individualmente, as taxas de classificação obtidas ficaram entre 40% e 86%, sendo que as que provaram ser menos susceptíveis a influência do ruído foram as do domínio da frequência. O fato do trabalho aqui apresentado ter lidado com sinais associados a baixos níveis de força de contração, mesmo não tendo propositadamente induzido ruído, o fato das características no domínio da frequência terem mostrado um melhor desempenho pode estar também relacionado à relação sinal ruído.

As características no domínio da frequência, avaliadas neste trabalho, foram também utilizadas em [13] que, para o reconhecimento de 6 padrões de preensão, obteve resultados semelhantes, com a diferença que a PSD_Av obteve um resultado inferior. Considerando as características no domínio do tempo as taxas obtidas foram da ordem de 65%, a PSD_Av obteve taxas de classificação da ordem de 54%, e o PSD_Mo 62%. Esses índices são próximos aos obtidos na configuração com 5 classes; situação em que as posições angulares diferem em 20° entre si. Já com relação aos padrões de preensão, são 4 bem distintos; preensão de precisão, lateral, cilíndrica e esférica com mais duas graduações nos dois últimos padrões.

Em [13], apesar do processo de classificação ter sido feito com uma Rede Neural, a inclusão de duas posições intermediárias, tanto entre os estados de flexão/extensão de punho, como para os de pronação/supinação do antebraço, resultando em configurações com 4 classes, resultou no decréscimo das taxas de acerto. Utilizando a ARV como característica, os autores obtiveram taxas de classificação de 84% e 55%, respectivamente. Para a mesma característica, configuração de classes e movimento, neste trabalho obteve-se taxas compatíveis.

Para MHSC1 as taxas médias foram de 82,62% e 83,81% para as fases de flexão e extensão respectivamente, e para o MHSC2 obteve-se 80% de classificação. Contudo, usando a PSD_Av as taxas médias para o MHSC1 aumentam para 87,86% e 90,25% e para o MHSC2 aumentou para 84%.

Conclusões

Na configuração de experimento utilizada, o aumento do número de classes representadas por posições angulares do cotovelo, resultou em um aumento da semelhança entre elas e, portanto, em uma diminuição característica das taxas de classificação. Comparando as configurações de movimento, o padrão de resposta obtido foi o mesmo, seja para o realizado de maneira gradual, ou para aquele com diferentes amplitudes, apesar do primeiro caso ter obtido taxas de classificação ligeiramente superiores. Dentre as características do sinal mioelétrico avaliadas, as no domínio da frequência mostraram um melhor desempenho, sendo o PSD_Av àquela que apresentou as melhores taxas médias de classificação, com 100%, 95%, 90%, 80% e 57% para as configurações com 2, 3, 4, 5 e 10 posições angulares do movimento gradual durante a fase de extensão.

Agradecimentos

Os autores agradecem à FEI pelo financiamento do projeto através de bolsa PBIC-77/11 e à FAPESP.

Referências

- [1] Ahsan, Md. R., Ibrahimy, M. I., Khalifa, O. O. (2009) "EMG signal classification for human computer interaction: a review" *European Journal of Scientific Research*, v. 33, n. 3, p. 480-501.
- [2] Parker, P., Englehart, K., Hudgins, B. (2006) "Myoelectric signal processing for control of powered limb prostheses" *Journal of Electromyography and Kinesiology*, v. 16, p. 541-548.
- [3] Li, G. (2011) "Electromyography pattern recognition based control of powered multifunctional upper limb prostheses," In: *Advances in Applied Electromyography*, Ed. J. Mizrahi, InTech, p. 99-116, Disponível em: <http://www.intechopen.com/books/advances-in-applied-electromyography/electromyography-pattern-recognition-based-control-of-powered-multifunctional-upper-limb-prostheses>. Acesso em Abr. 2012.
- [4] Scheme, E., Englehart, K. (2011) "Electromyogram pattern recognition for control of powered upper-limb prostheses: State of the art and challenges for clinical use," *The Journal of Rehabilitation Research and Development*, v. 48, n. 6, p. 643-660.
- [5] Hudgins, B., Parker, P., Scott, R. N. (1993) "A new strategy for multifunction myoelectric control," In: *IEEE Trans. Biom. Eng.*, vol. 40(1), p. 82-94, jan.
- [6] Lorrain, T. , Jiang, N., Farina, D. (2010) "Surface emg classification during dynamic contractions for multifunction transradial prostheses." In: *Proceedings of the International Conference of IEEE Engineering in Medicine and Biology Society*, pp. 2766-2769.
- [7] Geng, Y., Yu, L., You, M., Li, G. (2010) "A pilot study of emg pattern based classification of arm functional movements," In

Proceedings of the 2nd WRI Global Congress on Intelligent Systems, pp. 317–320.

- [8] Oskoei, M. A., Hu, H. (2006) “ GA-based Feature Subset Selection for Myoelectric Classification,” In: *Proc. IEEE Int. Conf. Robotics Biomimetics*, China, p. 1465-1470, dec.
- [9] Phinyomark, A., Chusak, L.; Pornchai, P. (2009) “A Novel Feature Extraction for Robust EMG Pattern Recognition” In: *Journal of computing*, v.1(1). p.71-80.
- [10] Du, S.; Vu, M. (2004) “Temporal vs. Spectral Approach to Feature Extraction from Prehensile EMG Signals,” In: *IEEE Int. Conf. Inf. Reuse Integration*, p. 344-350.
- [11] Belhumeur, P. N., Hespanha, J. P., Kriegman, D. J. (1997) “Eigenfaces vs Fisherfaces: recognition using class specific linear projection” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 19, n. 7, p. 711-720.
- [12] Guo, Y., Hastie, T., and Tibshirani, R. (2007) “Regularized linear discriminant analysis and its application in microarrays” *Biostatistics*, v. 8, n. 1, p. 86-100.
- [13] Itakura, N., Kinbara, Y., Fuwa, T., Sakamoto, K. (1996) “Discrimination of Forearm’s Motions by Surface EMG Signals using Neural Network,” In: *Appl. Hum. Sci: J. Physiol. Anthropol.*, vol. 15(6), p.287-294.