

# ESTUDO DA ANÁLISE DE DISCRIMINANTES LINEARES COMO UM CLASSIFICADOR ESTATÍSTICO DE SINAIS MIOELÉTRICOS

Caio Gerab Tramontina, Maria Cláudia F. Castro

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

mclaudia@fei.edu.br

**Abstract:** The Regularized Linear Discriminant Analysis (RLDA) has shown, in a previous work, to be a reliable method to describe class separability, and motivated this work aiming at studying the ability of this method in classifying the elbow angular position by means of myoelectric signal. The influence of parameters such as muscle, number and proximity of classes (angular positions), number of components used for projection and the regularization parameter on the classification accuracies were investigated. In one study, the data were processed for each volunteer and the results showed, for a number of classes from 2 to 4, average classification accuracies in the range from 97.3% to 77.9% respectively. In another study, the data of all volunteers were considered together in each sample, as in the previous work. The average classification rates were smaller showing that the method did not deal with the variability inter-subjects in performing a generic response.

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

## Introdução

O sinal mioelétrico, como uma expressão do controle do sistema nervoso sobre o sistema muscular, retém informações sobre a intenção de movimento do indivíduo. O estudo e domínio das características destes sinais torna possível a criação de interfaces homem-máquina, como por exemplo, exoesqueletos e próteses, cada vez mais dinâmicas e com maior capacidade de movimentos [1,2].

Durante os últimos anos foram propostas várias técnicas de processamento visando discriminar diferentes posições e/ou movimentos, conhecidos como classes, distinguindo-se, por exemplo, a flexão e extensão do cotovelo ou do punho, a supinação ou pronação do antebraço, desvio radial e ulnar do punho e padrões de gestos manuais. Para o reconhecimento de padrões, após a extração de características envolvendo análises no domínio do tempo ou da frequência, vários modelos matemáticos têm sido estudados, entre eles Redes Neurais, Lógica Fuzzy, Máquinas de Suporte Vetoriais e Análise de Discriminantes Lineares [1-8].

Em um trabalho anterior de comparação de algumas abordagens estatísticas, como a Análise de Componentes Principais (PCA), a Análise de Discriminantes Lineares (LDA), e suas variações como a aplicação da PCA antes da LDA, a MLDA (*Maximum uncertainty* LDA) e a LDA Regularizada (RLDA), [9] verificou uma maior eficiência da RLDA na separação de classes baseadas em posições angulares do cotovelo, inclusive para situações com 18 classes.

A alta capacidade de separação de classes demonstrada pela RLDA, independentemente de parâmetros como influência de músculos, movimentos, número e proximidade entre classes, motivou o estudo de sua capacidade como classificador. O desafio desse trabalho consiste na utilização desta técnica como classificador aplicado à envoltória de sinais mioelétricos, que não é uma característica usual, durante contrações de baixa intensidade, visando identificar posições angulares do cotovelo, que detém um baixo poder discriminatório dependendo da configuração, como por exemplo, posições com diferenças angulares de 10° e 20° entre si. Além dos parâmetros já citados no estudo anterior [9], são estudados a influência da fase dinâmica e estática do movimento bem como o poder de generalização da técnica para lidar com a variabilidade inter-sujeitos.

## Análise de Discriminantes Lineares

A LDA é um método estatístico que busca maximizar a dispersão entre as classes (1) enquanto minimiza a dispersão dos dados intra-classes (2), sendo  $g$  o número de classes,  $N_i$  o número de amostras na classe  $X_i$ ,  $\bar{x}_i$  a média da classe  $X_i$  e  $\bar{x}$  o vetor média total, considerando todas as amostras de todas as  $g$  classes [10-12].

$$S_b = \sum_{i=1}^g N_i (\bar{x}_i - \bar{x})(\bar{x}_i - \bar{x})^T \quad (1)$$

$$S_w = \sum_{i=1}^g \sum_{x_k \in X_i} (x_k - \bar{x}_i)(x_k - \bar{x}_i)^T \quad (2)$$

De acordo com o critério de Fisher esta questão pode ser resolvida como um problema de autovetores e autovalores, onde  $\phi$  e  $\lambda$  são respectivamente os autovetores e autovalores de  $S_b S_w^{-1}$  com no máximo ( $g-1$ ) autovalores diferentes de zero.

$$S_b \phi = \lambda S_w \phi \quad (3)$$

Entretanto, em aplicações práticas, a matriz de dispersão  $S_w$  é singular ou próxima disto, pelo fato de que, geralmente, o número de amostras  $N_i$  é muito menor do que a dimensão  $d$  dos dados [10-12].

Para lidar com esta limitação, um dos métodos propostos na literatura, o RLDA, propõem a adição de uma constante  $\alpha$ , conhecida como fator de regularização, aos elementos da diagonal da matriz  $S_p$  (4). Este processo estabiliza a matriz de covariância e melhora a eficiência do classificador [11-13].

$$S_p = S_w / (N - g) \quad (4)$$

## Materiais e Métodos

Foram adquiridos sinais mioelétricos do bíceps braquial e do tríceps braquial durante movimentos de flexão e extensão do cotovelo, no plano horizontal, sem carga. Os voluntários foram orientados a realizar o movimento sem força adicional, fazendo com que a intensidade da contração se mantivesse sempre baixa. Durante os movimentos, a posição angular do cotovelo também foi monitorada. Sete voluntários (4 homens e 3 mulheres) entre 25 e 45 anos participaram da pesquisa, com protocolo aprovado COEP – USJT - N°.076/2010.

Partindo da posição em extensão  $0^\circ$ , o movimento foi realizado em incrementos de  $10^\circ$  a cada 3s, variando até  $90^\circ$  e retornando para a posição de extensão da mesma forma, resultando em um total de  $g=18$  classes (9 para extensão e 9 para flexão).

O sinal mioelétrico de superfície foi amostrado em 1 kHz, filtrado entre 20 e 500 Hz, e retificado para obtenção da envoltória do sinal.

Em um primeiro estudo, foram considerados os dados durante o posicionamento estático com incrementos de  $10^\circ$ . Ou seja, assim que uma posição angular foi atingida, os 3s de intervalo para a sequência do movimento foi considerado para seleção de dados da fase estática. Para cada voluntário, foram utilizados  $N_i=15$  amostras por classe, com  $d=200$  ms de dimensão, para cada posição angular, ou  $N_i=105$  amostras por classe considerando todos os voluntários em um mesmo grupo. De acordo com [14] os 200 ms iniciais da contração muscular contém informações determinísticas do movimento. Sendo assim, para um segundo estudo, foram utilizados os primeiros 200 ms de cada movimento, ou seja, durante o processo dinâmico. Vale ressaltar que não se tratam de contrações isométricas, mas as obtidas durante a variação angular (fase dinâmica). E considerando os incrementos de  $10^\circ$ , resultou em  $N_i=21$  amostras por classe, considerando os dados dos 7 voluntários em conjunto.

A intenção do estudo foi o de avaliar a influência do número e proximidade entre as classes no processo de classificação, e também a influência da contribuição muscular, com dados provenientes do bíceps e tríceps em conjunto ou individualmente. Além disto, parâmetros como número de componentes resultantes da redução de dimensionalidade e o parâmetro de

regularização  $\alpha$ , cujo valor foi variado entre  $10^{-7}$  e 0,9 também foram investigados.

Por conta do baixo número de amostras, o método *Leave one out* foi utilizado para a seleção dos conjuntos de treinamento e teste. A atribuição das classes foi feita através de Distância Euclidiana, com os dados projetados pela RLDA.

## Resultados

A Figura 1 mostra as taxas médias de classificação alcançadas utilizando dados de ambos os músculos. O grupo 1 corresponde à média dos resultados dos sete voluntários, enquanto o grupo 2 desconsiderou os resultados de dois voluntários, que apresentaram índices de classificação bem abaixo dos demais, muito provavelmente devido a problemas de posicionamento de eletrodos. Independentemente do grupo utilizado, as taxas de classificação mais altas foram obtidas durante a fase de extensão, sendo que para 2 classes, as taxas médias de classificação ficaram entre 97,14 e 98,67%, enquanto para 5 classes, as taxas diminuíram para um intervalo entre 66,86% e 76,27%.

Os resultados para duas classes são referentes às posições estáticas em  $0^\circ$  e  $90^\circ$ , os resultados para 3 classes são referentes às posições em  $10^\circ$ ,  $50^\circ$  e  $90^\circ$ ; já para o caso de 4 classes foram utilizados os dados das posições de  $0^\circ$ ,  $30^\circ$ ,  $60^\circ$  e  $90^\circ$ , e no caso de 5 classes,  $10^\circ$ ,  $30^\circ$ ,  $50^\circ$ ,  $70^\circ$  e  $90^\circ$ . Por último, no caso de 10 classes, todas as posições em incrementos de  $10^\circ$  foram consideradas.

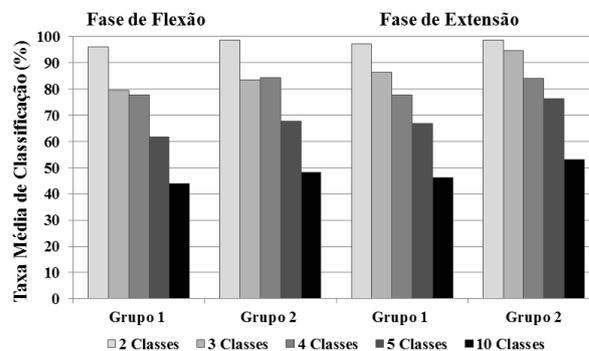


Figura 1 – Taxas médias de classificação para posição estática considerando dois grupos de voluntários.

Já os gráficos das Figuras 2 e 3 apresentam os resultados individuais de dois sujeitos (A e B), que obtiveram as taxas de classificação mais altas e as mais baixas, respectivamente, para cada configuração de músculo e classe. Observando-se os resultados da Figura 2, nota-se que, para uma mesma configuração de classe e fase do movimento, as taxas de classificação obtidas utilizando os dados de ambos os músculos foi superior às obtidas com os dados dos músculos individualmente. Para ensaios com 5 classes, foi possível obter índices acima de 80%, sendo que os melhores resultados ocorreram na fase de flexão. Para ensaios com menor número de classes, foi possível

atingir até 100% de classificação. Estes resultados foram obtidos utilizando valores de  $\alpha$  entre  $10^{-3}$  e 0,9, escolhidos de modo a maximizar as taxas de classificação. Por outro lado, observando-se os resultados da Figura 3, além dos índices apresentados serem, de modo geral, bem menores do que os apresentados na Figura 2, considerando uma mesma configuração de classe e fase de movimento, mostram taxas de classificação utilizando dados do tríceps muito próximas das obtidas com os dados de ambos os músculos. Pode-se dizer que, esse resultado atípico, comparativamente aos demais, pode ser uma expressão de falha no posicionamento dos eletrodos do bíceps, fazendo com que os dados desse músculo não tenham contribuído de maneira significativa no processo de reconhecimento e classificação de padrões.

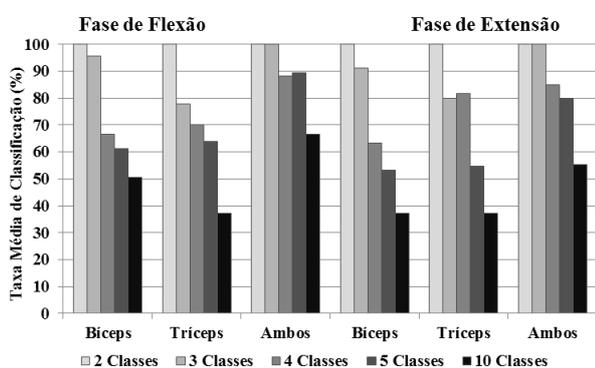


Figura 2 – Maiores taxas de classificação (sujeito A).

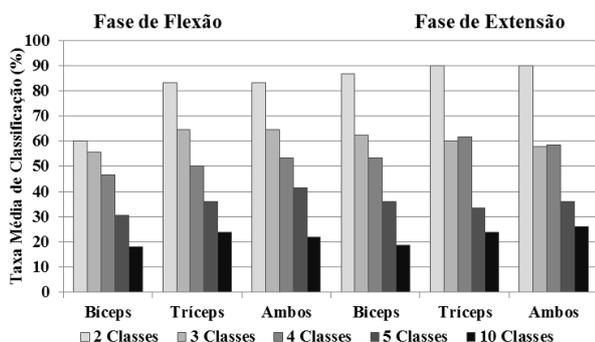


Figura 3 – Menores taxas de classificação (sujeito B).

A Figura 4 mostra os resultados obtidos com os dados de todos os voluntários considerados em conjunto para criar as amostras de treinamento e teste, tanto no estudo envolvendo as posições estáticas como no estudo dinâmico, considerando os dados da fase inicial do movimento. Neste caso, 3 classes correspondem às transições de  $0^{\circ}$ - $10^{\circ}$ ,  $40^{\circ}$ - $50^{\circ}$ ,  $80^{\circ}$ - $90^{\circ}$  ou  $90^{\circ}$ - $80^{\circ}$ ,  $50^{\circ}$ - $40^{\circ}$  e  $10^{\circ}$ - $0^{\circ}$  de acordo com o sentido do movimento (flexão ou extensão), e todos esses intervalos para a configuração de 6 classes (flexão e extensão). Já a configuração de 5 classes envolve as transições de  $0^{\circ}$  -  $10^{\circ}$ ,  $20^{\circ}$ - $30^{\circ}$ ,  $40^{\circ}$ - $50^{\circ}$ ,  $60^{\circ}$ - $70^{\circ}$ , e  $80^{\circ}$ - $90^{\circ}$  ou  $90^{\circ}$ - $80^{\circ}$ ,  $70^{\circ}$ - $60^{\circ}$ ,  $50^{\circ}$ - $40^{\circ}$ ,  $30^{\circ}$ - $20^{\circ}$ , e  $10^{\circ}$ - $0^{\circ}$  conforme o sentido do movimento, e de mesmo modo, todos esses intervalos em conjunto formam a configuração de 10 classes

(flexão e extensão). A classe identificada como 10\* é formada por todos os intervalos com incrementos de  $10^{\circ}$ , e para o estudo das posições estáticas, os pontos correspondem à posição angular final dos intervalos acima descritos.

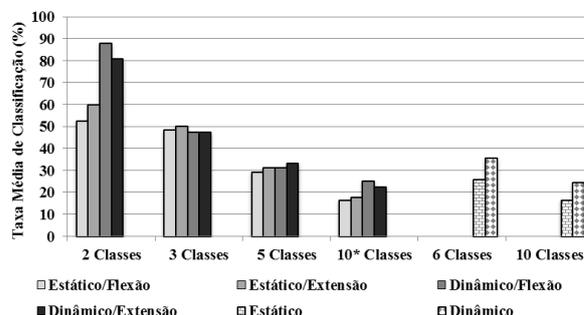


Figura 4 – Taxas de classificação considerando os dados de todos os voluntários em conjunto.

Com exceção dos resultados obtidos para 2 classes, houve uma redução significativa nas taxas de classificação considerando os dados de diferentes sujeitos. Entretanto, não foi possível notar grandes diferenças entre os resultados obtidos para as posições estáticas e os dados referentes à fase inicial do movimento para a maioria das configurações de classes. A diferença mais marcante se deu no parâmetro de regularização, que para dados referentes ao início do movimento se encontrou entre 0,1 e 0,9 enquanto, para a análise das posições estáticas, variou entre  $10^{-4}$  e 0,9, sendo que os menores valores foram utilizados nos casos de maior número de classes.

O número de componentes usado para as análises presentes na Figura 4 foi aquele necessário para reter 99% da informação do sinal. De modo geral, não foram observadas alterações significativas a partir do uso de um número maior que 5 componentes para a classificação de 10 classes.

## Discussão

Embora grande parte da literatura tenha reportado altas taxas de classificação (entre 85-95%) e consequentemente baixos índices de erro, é importante ressaltar as diferenças nas características dos estados usados para constituição das classes. De maneira geral, são analisados estados de flexão e extensão do cotovelo ou punho, supinação e pronação do braço e abertura e fechamento da mão, sendo que as classes obtidas nestes movimentos são muito diferentes entre si; ou seja, não são utilizados estados intermediários. Além disto, a maioria dos estudos utiliza contrações isométricas ou movimentos com execução de força de intensidade média, o que resulta em um sinal mioelétrico de maior intensidade. Por último, todos eles utilizam algum método de extração de características [3-8].

Em contrapartida, os resultados aqui exibidos foram obtidos utilizando dados de movimentos próximos do normal, executados com um baixo nível de força.

Adicionalmente, é importante ressaltar que uma análise com 4 classes significa posições com diferença de 30° entre si, e para uma análise com 5 classes, essa diferença cai para 20°, o que resulta em estados muito semelhantes entre si. Por último, os dados utilizados são oriundos diretamente da envoltória do sinal mioelétrico, que não é uma característica usual.

Portanto, pode-se considerar que os resultados exibidos na Figura 1 são satisfatórios. Adicionalmente, ao analisar os resultados da Figura 2, observa-se que eles são ainda melhores, permitindo a utilização de classes distantes em apenas 20° com até 80% de classificação. Comparando resultados gerados para 2 classes, estados de extensão/flexão, configuração que se assemelha aos demais trabalhos, não pelo número de classes, mas pela característica dos estados que as compõem, a taxa média de classificação chegou a 98,7%, valor superior ao relatado pela literatura.

Entretanto, quando os dados de todos os voluntários foram considerados em conjunto, a RLDA foi incapaz de classificar corretamente as classes propostas, com exceção do ensaio para 2 classes com dados referentes ao início dos movimentos (fase dinâmica). As melhores taxas obtidas ficaram em torno de 50%. Estes resultados exemplificam e confirmam a alta variabilidade entre os indivíduos, sendo que a RLDA não conseguiu generalizar o sistema para uma resposta padrão. Ao se comparar resultados obtidos com dados referentes às posições estáticas e do início dos movimentos, o segundo apresentou melhores taxas de classificação, porém, sem diferenças significativas.

De acordo com [14] as informações determinísticas de uma contração muscular estão nos seus instantes iniciais. Já [15], a partir da comparação entre dados de contrações estáticas e dinâmicas, encontraram informações mais significativas na fase estática, provavelmente em função da movimentação dos eletrodos durante a execução do movimento. De acordo com [8] a maior concentração de erros de classificação são encontrados no início e no final das contrações, pois segundo ele, são os instantes mais próximos dos momentos de descanso. Apesar das baixas taxas de classificação, os resultados mostraram que para ambos os casos as taxas médias de classificação foram similares, de modo que o erro não variou significativamente em relação ao estágio do movimento em que os dados foram adquiridos, mas sim por causa da utilização de dados de diversos voluntários simultaneamente. Entretanto, para uma análise mais conclusiva, é necessário se fazer uma investigação sobre o efeito da utilização dos dados da fase dinâmica para cada voluntário individualmente, e a aplicação de outras técnicas que possuam maior poder de generalização.

A pesquisa de [9] demonstrou que o processo de separação de classes se mostrou mais eficiente ao se utilizar os dados provenientes do bíceps se comparados aos resultados obtidos com dados referentes ao tríceps (que apresentou maior dispersão entre os pontos). Já a utilização dos dados de ambos os músculos em conjunto resultou em um aumento da eficiência de separação das

classes. Do mesmo modo, os dados das Figuras 2 e 3 também evidenciaram que as taxas de classificação, geradas por dados de ambos os músculos, foram iguais ou maiores do que os valores obtidos a partir de dados de um único músculo. Estes resultados estão de acordo com a natureza fisiológica do problema, já que ambos os músculos auxiliam no controle de cada movimento, embora, dependendo da fase, a participação de um deles se torna mais predominante do que a do outro.

Mesmo que confirmada pelo experimento aqui exposto, de acordo com [3], uma melhor separabilidade não garante necessariamente melhores resultados na fase de classificação. Além disto, no caso deste trabalho, outro ponto que necessita ser analisado é o valor do parâmetro de regularização. O grau de separação entre classes é diretamente dependente deste parâmetro, sendo que [9] mencionou o uso de valores próximos de zero ( $10^{-5}$ ) para otimizar os resultados (Figura 5).

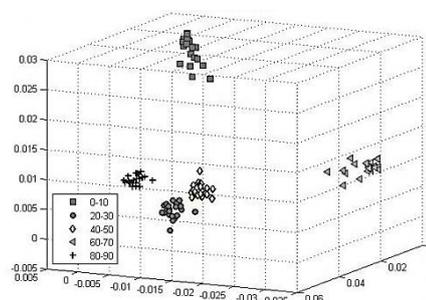


Figura 5: Dados do bíceps e tríceps (considerados em conjunto) projetados nas três componentes mais discriminantes da RLDA ( $\alpha=10^{-5}$ ).

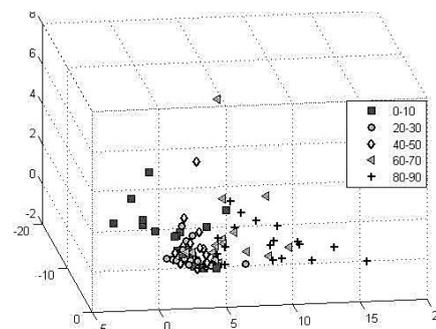


Figura 6: Dados do bíceps e tríceps (considerados em conjunto) projetados nas três componentes mais discriminantes da RLDA ( $\alpha=0,9$ ).

Entretanto, com o objetivo de classificação, os valores de  $\alpha$  que, na maior parte das vezes, geraram melhores resultados, foram aqueles próximos de 1 (entre 0,9 e 0,1). Quanto mais este fator se aproxima de 1, maior se torna a dispersão entre os dados, como se pode observar na Figura 6, dificultando o processo de separação das classes. Contudo, a primeira situação pode significar uma especialização do sistema a uma parte dos dados enquanto a segunda significaria um sistema mais generalista. Além disto, como a atribuição

de classes, durante a classificação, foi baseada na distância Euclidiana, relacionada ao centro destas classes, mesmo com a sobreposição ilustrada na Figura 6, os centros podem estar posicionados de forma a proporcionar uma boa classificação no espaço das projeções.

O número de componentes necessárias para classificar corretamente as classes está diretamente ligado ao número de projeções que conseguiram ao mesmo tempo reter as informações características e descartar as informações redundantes. O número máximo de componentes está limitado ao número de classes de classificação menos 1. Para poucas classes como 2 ou 3, o número de componentes já é bem reduzido, mas para o caso de 5, 6 e 10 classes, apesar de termos disponíveis 4, 5 e 9 componentes, respectivamente, normalmente, a partir de 3 a 5 componentes, o aumento deste número deixa de melhorar significativamente os resultados da taxa de classificação. A contribuição maior de informação está retida nas primeiras componentes, restando as demais um grau de significância menor.

A maneira como a RLDA foi utilizada em [9] se mostrou eficiente para a descrição e agrupamento dos dados, porém, na tentativa de generalizar o sistema para uma resposta padrão, a utilização do método como classificador não alcançou os mesmos resultados obtidos anteriormente para a separação de classes.

Por outro lado, considerando as características individuais de cada voluntário, os resultados mostraram que para poucas classes, utilizando apenas dados da envoltória do sinal, o método é capaz de classificar corretamente. É possível também que para maior quantidade de classes a utilização de métodos de extração de características possa melhorar o processo de classificação.

## Conclusão

Este trabalho mostrou que para uma pequena quantidade de classes (até 5), o uso da envoltória do sinal mioelétrico, em contraste à extração de características, comumente utilizada, associado à RLDA, foi suficiente para classificar corretamente posições angulares do cotovelo distantes entre si em pelo menos 20°.

A configuração do tipo de músculo analisado, fase do movimento e parâmetro de regularização, que se manteve próximo de 1, tiveram influência direta sobre a precisão do classificador.

Em contrapartida, a metodologia aqui adotada foi incapaz de lidar com dados provenientes de diferentes voluntários ao mesmo tempo, na tentativa de generalizar o problema a uma solução padrão.

## Agradecimentos

Os autores agradecem à FEI pelo financiamento do projeto através de bolsa PBIC-52/10 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] Chu, J. -U., Moon, I., Mun, M. S. (2006) "A Real-Time EMG Pattern Recognition System Based on Linear-Nonlinear Feature Projection for a Multifunction Myoelectric Hand" *IEEE Transactions on Biomedical Engineering*, v. 53, n. 11, p. 2232-2239.
- [4] Favieiro, G. W., Balbinot, A., Barreto, M. G. (2011) "Decoding Arm Movements by Myoelectric Signals and Artificial Neural Networks" In: *Proceedings of the ISSNIP Biosignals and Biorobotics Conference*, Vitoria, Brazil. DOI: 10.1109/BRC.2011.5740677.
- [5] 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 2<sup>nd</sup> WRI Global Congress Intelligent Systems*, p. 317-320. DOI: 10.1109/GCIS.2010.125.
- [6] Khezri, M., Jahed, M. (2007) "Real-time intelligent pattern recognition algorithm for surface EMG signal" *BioMedical Engineering Online*, 6:45, DOI: 10.1186/1475-925X-6-45.
- [7] Khokhar, Z. O., Xiao, Z. G., Menon, C. (2010) "Surface EMG pattern recognition for real-time control of a wrist exoskeleton" *BioMedical Engineering Online*, 9:41. DOI: 10.1186/1475-925X-9-41.
- [8] Lorrain, T., Jiang, N., Farina, D. (2010) "Surface EMG classification during dynamic contractions for multifunction transradial prostheses" In: *Proceedings of the 32<sup>nd</sup> Annual International Conference IEEE EMBS*, Buenos Aires, Argentina. DOI: 10.1109/IEMBS.2010.5626587.
- [9] Castro, M. C. F. (2011) "Statistical Approach for Angular Position Separability Classes of EMG Data" In: *Proceedings of the ISSNIP Biosignals and Biorobotics Conference*, Vitoria, Brazil. DOI: 10.1109/BRC.2011.5740663.
- [10] 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.
- [11] Thomaz, C. E., Kitani, E. C., Gillies, D. F. (2006) "A maximum uncertainty LDA-based approach for limited sample size problems – with application to face recognition" *Journal of the Brazilian Computer Society*, v. 12, n. 2, p. 7-18.
- [12] Ye, J., et al. (2006) "Efficient model selection for regularized linear discriminant analysis" In: *Proceedings of the 15<sup>th</sup> ACM International Conference of Information Knowledge Management*, Virginia, USA, p. 532-539.
- [13] 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.
- [14] Hudgins, B., Parker, P., and Scott, R. N. (1993) "A New Strategy for Multifunction Myoelectric Control" *IEEE Transactions on Biomedical Engineering*, v. 40, n. 1, p. 82-94.
- [15] Englehart, K., Hudgins, B., Parker, P. A. (2000) "Time-Frequency Based Classification Signal: Static vs. Dynamic Contractions" In: *Proceedings of the 22<sup>nd</sup> Annual International Conference IEEE EMBS*, Chicago, USA, v. 1, p. 317-320.