

RECONHECIMENTO DA POSIÇÃO INDIVIDUAL DOS DEDOS ATRAVÉS DA ANÁLISE DE DISCRIMINANTES LINEARES

Luiz V. Esteves 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 study aims to investigate the recognition of flexion movements of each of the fingers of the hand, through the association of Principal Components Analysis and Linear Discriminant Analysis. The work began with the myoelectric signal envelope of a total of 6 finger flexor and extensor muscles, and a process of optimization was done to attain the minimum and best suitable muscle combination. The results showed that there is not a general pattern of muscle configuration and that an optimal configuration is dependent not only of the subject, but also of the movement that intends to be recognized. Analyzing each finger movement separately, on average it can be recognized with a maximum of 4 muscles with rates that varied from 88.75% for the thumb to 97.08% for the ring finger. On the other hand, analyzing the movements together, on average it was necessary a combination of 5 muscles among those studied with 78.47% of classification. The ring finger was the most easily recognized among the fingers, while the neutral position was the one that had the greatest difficulty of being recognized.

Palavras-chave: Reconhecimento de Padrões, Análise de Discriminantes Lineares (LDA), Sinal Mioelétrico, Flexão dos dedos.

Introdução

O desenvolvimento de exoesqueletos e próteses comandados por sinais mioelétricos, representando a intenção de movimento do sujeito e procurando suprir suas perdas motoras têm proporcionado a obtenção de soluções para a reabilitação de pessoas com deficiências nos membros superiores [1-3]. Porém, o desenvolvimento de dispositivos multifuncionais, associado à característica variável do sinal mioelétrico, requer um alto poder de discriminação dos sistemas relacionados ao reconhecimento de movimentos do braço, punho e/ou dos dedos, possível a partir do desenvolvimento de algoritmos de reconhecimento de padrões [4-12].

O reconhecimento de padrões pode ser realizado pela aplicação de várias técnicas, sendo as mais comuns, as Redes Neurais Artificiais (RNA) [4-7], as Máquinas de Suporte Vetoriais (SVM) [8, 9] e a Análise de Discriminantes Lineares (LDA) [7, 10].

Porém, devido à característica estocástica do sinal mioelétrico, uma fase de extração de características é aplicada antes da fase de reconhecimento de padrões, de modo a obter informações úteis do sinal. Em geral, as características mais comuns são as do domínio do tempo, como o Valor Quadrático Médio (RMS), Valor Médio Absoluto (MAV), Comprimento de Onda (WL), e a variância do sinal mioelétrico [4-7] entre outras, mas também se encontram aplicações com a Integral do sinal mioelétrico que é uma forma de suavizar o sinal original obtendo a sua envoltória [8], coeficientes do modelo auto-regressivo (AR) [11], Densidade Espectral de Potência, Transformada de Fourier, e Wavelets e suas variações [7, 9], Componentes Independentes [12]. Este processo de extração de características, por ser aplicado sobre um janelamento dos dados originais, também obtém uma redução da dimensionalidade dos dados. A aplicação da Análise de Componentes Principais (PCA) é outra ferramenta que reduz a dimensionalidade dos dados e também tem sido utilizada [12,13].

Tendo em vista o grande número de graus de liberdade do movimento dos dedos e o reduzido número de movimentos disponíveis nas próteses comerciais, o presente trabalho se propõe a estudar o reconhecimento de movimentos de flexão de cada um dos dedos da mão, através da associação da PCA e da LDA. O ponto de partida foi a envoltória dos sinais mioelétricos de músculos flexores e extensores dos dedos, num total de 6, e um processo de otimização foi feito para verificar a mínima e melhor combinação de músculos.

Análise de Componentes Principais

A PCA consiste na obtenção de combinações lineares dos dados e projetá-las nas direções de maior variabilidade do conjunto. Geometricamente, representa a translação da origem do sistema de eixos para o ponto correspondente à média dos dados e a rotação nas direções de maior variabilidade.

Este processo baseia-se em operações envolvendo autovalores e autovetores da matriz de covariância, sendo que os autovetores correspondentes aos maiores autovalores são as chamadas Componentes Principais, que definem as direções de maior variabilidade. Dessa forma, os autovetores correspondentes aos menores autovalores podem ser desconsiderados por

apresentarem menor significância, resultando assim no processo de redução de dimensionalidade [13, 14].

Análise de Discriminantes Lineares

A LDA projeta os dados em uma nova direção de forma que a variabilidade dentro de cada classe, pré-definida, seja reduzida, e simultaneamente a variabilidade entre as classes seja aumentada, de modo a permitir a distinção entre elas.

A variabilidade dentro de cada classe é definida pela matriz de covariâncias S_w (1), e a variabilidade entre as classes é caracterizada pela matriz de covariâncias S_b (2), onde g é o número de classes, x_k é um dado pertencente à classe X_i , \bar{x}_i é a média da classe X_i , N_i é o número de elementos de cada classe e por fim \bar{x} é a média entre todas as classes [15,16].

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

$$S_b = \sum_{i=1}^g N_i (\bar{x}_i - \bar{x})(\bar{x}_i - \bar{x})^T \quad (2)$$

Fisher propõe a maximização da equação (3), que pode ser solucionada por uma operação envolvendo autovalores e autovetores (4), onde ϕ e γ são respectivamente os autovetores e os autovalores de $S_b S_w^{-1}$ [15,16].

$$W_{lda} = \left| \frac{W^T S_b W}{W^T S_w W} \right| \quad (3)$$

$$S_b \phi = \gamma S_w \phi \quad (4)$$

Materiais e Métodos

Base de Dados – A coleta de dados envolveu seis voluntários submetidos a um protocolo aprovado em comitê de ética em pesquisa COEP-USJT – No 088/2011. Durante o experimento, cada voluntário permaneceu sentado, com o braço apoiado e fletido em 90°. Partindo sempre da posição neutra do punho, com a palma da mão na vertical, polegar voltado para cima e com os dedos estendidos, movimentos de flexão da articulação metacarpo-falangeana foram realizados, com cada um dos dedos individualmente, iniciando pelo polegar e continuando, sequencialmente, com os dedos indicador, médio, anular e mínimo. Cada dedo permaneceu flexionado por 3s e na sequência retornava à posição neutra por mais 3s. Foram realizadas seis sessões, cada uma com cinco repetições da mesma sequência de movimentos, com um intervalo de descanso de 5 min entre as sessões. Os voluntários foram previamente instruídos a não exercerem força superior àquela necessária a realização do movimento e não exercerem força adicional durante a fase estática. A aquisição foi feita com a utilização do equipamento PowerLab 16/30 associado ao Bioamplificador, ambos

da AdInstruments, com frequência de aquisição de 1000 Hz e filtro passa faixas de 20 Hz a 500 Hz. O sinal mioelétrico foi retificado e através de convolução com uma exponencial do tempo de decaimento de 0,1s foi obtida a sua envoltória.

Analisando os trabalhos de outros autores [4-10], verificou-se uma predominância na utilização dos músculos Extensor Comum dos Dedos, Extensor Ulnar do Carpo, Abductor Longo do Polegar, Palmar Longo e Flexor Superficial dos Dedos. Diante disto, os músculos escolhidos para monitoração, no presente trabalho, foram, conforme Figura 1, o Extensor Comum dos Dedos, o Abductor Longo do Polegar, o Extensor do Dedo Mínimo, o Palmar Longo e dois posicionamentos diferentes para o Flexor Superficial dos Dedos. O eletrodo de referência foi posicionado no epicôndilo medial do úmero.



Figura 1 – Posicionamento dos eletrodos.

Para a análise, foi selecionado 1s de dados na fase estática, com o dedo já em flexão, totalizando amostras de 30 séries para cada um dos dedos. Vale salientar, que os voluntários foram orientados a não exercerem nenhuma contração adicional proveniente de contração isométrica durante esta fase. Amostras dos sinais relacionados à posição neutra também foram considerados. Dessa forma, tendo em vista a frequência de aquisição de 1K Hz e o número de músculos monitorados, a dimensão da matriz inicial de dados corresponde a 6000 x 6000 (5 dedos + posição neutra x 6 músculos).

PCA – Visando à redução da dimensionalidade da matriz de dados a PCA foi aplicada ao conjunto total de dados a serem posteriormente classificados. Inicialmente, considerando os dados de todos os músculos tem-se, para cada sujeito, uma matriz de dados de dimensão 6000 x 6000. Ao longo do processo, combinações com um número menor de músculos foram consideradas e com isso a matriz de dados diminui de dimensão. Combinações com 5 músculos resultaram em matrizes de 6000 x 5000, combinações com 4 músculos em matrizes de 6000 x 4000 e assim sucessivamente. Independente da combinação a PCA foi aplicada ao conjunto de dados de cada sujeito, e o número de Componentes Principais consideradas foi o necessário para reter 95% da variabilidade dos dados.

Classificação – O processo de classificação foi feito, para cada sujeito, com a aplicação da LDA sobre os dados projetados nas direções definidas PCA, separando-os em amostra de treinamento e de teste

através da técnica *leave one out*. No caso da LDA, tendo em vista o objetivo de classificação de 6 classes distintas (posição neutra, polegar, e dedos indicador, médio, anular e mínimo), foram consideradas as 5 primeiras componentes para a projeção dos dados. A atribuição de classes, propriamente dita, foi feita através de distância Euclidiana.

Inicialmente, os dados de todos os músculos foram utilizados. Ao longo do processo, promoveu-se uma otimização do número de músculos envolvidos, a partir da identificação do músculo que menos contribuiu com o processo de reconhecimento. Ou seja, em cada etapa, combinações com um número menor de músculos foi testada, sendo considerada àquela que obteve a maior taxa de classificação para a continuidade do processo, consistindo na eliminação de mais um músculo e reavaliação das taxas de classificação e assim sucessivamente. Na primeira fase do experimento, o processo de otimização foi realizado, com os dados de cada sujeito, para a identificação de cada um dos movimentos separadamente. No segundo experimento, o mesmo processo foi repetido, porém com o objetivo de reconhecer cada um dos movimentos dentro do conjunto total de dados de cada sujeito.

Resultados

Os resultados apresentados por dois dos sujeitos envolvidos na pesquisa foram atípicos, apresentando taxas de classificação que se distanciaram do padrão dos demais, como mostra a Figura 2, para a classificação da posição de flexão de cada dedo avaliado separadamente em relação à posição neutra. As taxas de classificação dos sujeitos 3 e 6 foram praticamente constantes, independente da quantidade de músculos considerada (com exceção do sujeito 6, considerando 6 músculos), e de 20% a 30% inferiores às apresentadas pelos demais sujeitos. Isto pode estar relacionado ao mau posicionamento dos eletrodos, fator determinante dos resultados. Por este motivo, na análise que se segue os mesmos foram desconsiderados.

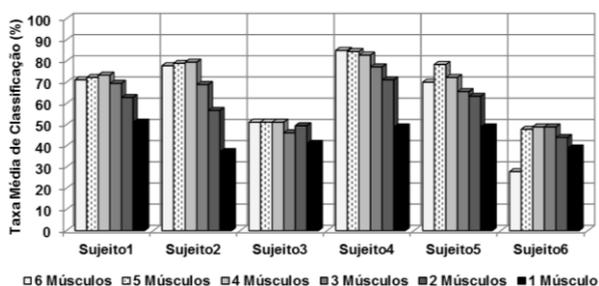


Figura 2 - Taxas médias de classificação em função do número de músculos considerado, para o reconhecimento da posição de flexão de cada dedo individualmente.

A configuração de músculos obtida para cada sujeito, para o reconhecimento de cada movimento separadamente, foi variável. Ou seja, não houve um

padrão na sequência de eliminação dos músculos ao longo do processo de otimização. Para cada sujeito e para cada movimento considerado, existiu uma combinação diferente que resultou na melhor taxa de classificação. De qualquer forma, a Figura 3 mostra que as maiores taxas médias de classificação ocorreram considerando os dados de 2 a 4 músculos. A flexão do dedo mínimo foi reconhecida, em média, com apenas 2 músculos, a abdução do polegar com 3, e os demais movimentos considerados foram reconhecidos, em média, considerando os dados de 4 músculos. Nessas situações, as taxas médias de reconhecimento variaram de 88,75% para o polegar, a 97,08% para o dedo anular.

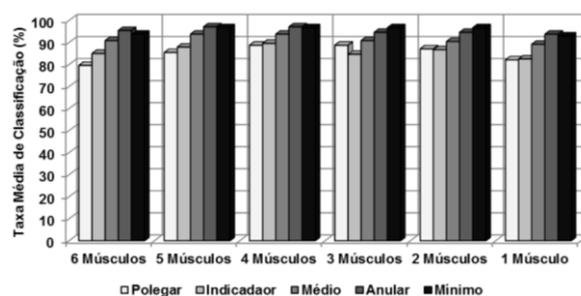


Figura 3 – Taxas médias de classificação em função do número de músculos considerado, para o reconhecimento da posição de flexão de cada dedo individualmente.

Durante o processo de otimização, os músculos que foram utilizados com maior frequência foram, para o reconhecimento da abdução do polegar, o Flexor Superficial dos dedos (eletrodo distal), Palmar Longo, Extensor do dedo mínimo; para o reconhecimento da posição de flexão do indicador, o Flexor superficial dos dedos (os dois eletrodos) e o Extensor comum dos dedos enquanto o reconhecimento da flexão do dedo médio utilizou, preferencialmente, o flexor superficial dos dedos (os dois eletrodos); já para o reconhecimento da posição de flexão do dedo anular foram utilizados o palmar longo e o extensor do dedo mínimo, enquanto que para a flexão do dedo mínimo o flexor superficial (eletrodo proximal) foi utilizado com maior frequência.

Na segunda fase do experimento, foi considerado todo o conjunto de dados de cada voluntário, resultando nas taxas de classificação indicadas na Figura 4. Notam-se taxas de classificação mais baixas, comparadas as anteriores, uma vez que neste caso o número de classes de reconhecimento aumentou de 2 para 6 movimentos, incluindo a posição neutra. A taxa de classificação média mais alta foi de 78,47% tendo sido obtida com uma combinação de 5 músculos. Considerando os resultados individuais de cada sujeito tem-se 85% com 6 músculos para o sujeito 4.

Da mesma forma que na primeira fase, não foi verificado um padrão único com relação à combinação de músculos. Para cada sujeito, existiu uma combinação diferente que resultou na melhor taxa de classificação. E apesar de ter havido variações, o dedo anular foi o mais facilmente reconhecido entre os dedos, enquanto a

posição neutra foi a que teve maior erro de classificação.

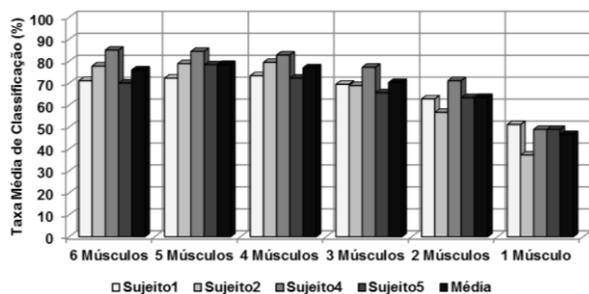


Figura 4 – Taxas médias de classificação em função do número de músculos considerado, para o reconhecimento da posição de flexão dos dedos.

Discussão

A primeira fase do trabalho, na qual se investigou a posição de cada dedo separadamente com relação à posição neutra, mostrou que não há um padrão geral de configuração muscular e que uma configuração ótima é dependente não apenas do sujeito, mas da posição (ou dedo) que se pretende reconhecer. Além disso, analisando de maneira mais profunda as configurações mais frequentes, nota-se a contribuição tanto de músculos flexores quanto de extensores na classificação da posição de flexão. Uma pequena diferença na ativação de um músculo extensor contribuiu na diferenciação dos movimentos de cada um dos dedos. Na média, cada um dos movimentos pôde ser reconhecido com no máximo 4 músculos, com taxas que variaram de 88,75% para o polegar a 97,08% para o dedo anular.

Na segunda fase, as taxas médias de classificação diminuíram uma vez que o número de classes aumentou. A ausência de padrão de configuração muscular se manteve, porém para o reconhecimento das posições dos dedos, na média foi necessário uma combinação de 5 músculos dentre os estudados.

O trabalho de [7] investigou o reconhecimento de movimentos individuais dos dedos durante exercícios de digitação, utilizando 8 pares de eletrodos dispostos ao redor do terço proximal do antebraço. Foram avaliadas várias combinações de número de canais, para cada um dos sujeitos que fizeram parte da pesquisa. Os resultados mostraram que a melhor configuração é dependente do sujeito, o que está de acordo com os resultados obtidos pelo processo de otimização aplicado neste trabalho, apesar do posicionamento ter sido diferente. E apesar das taxas médias de classificação terem um comportamento crescente em função do aumento do número de canais utilizado, variando de 54,3% com 1 canal a 91,4% com 8, considerando os valores obtidos para um mesmo sujeito, nota-se um crescimento até 4 ou 5 canais e a partir daí as taxas mantiveram-se praticamente constantes. Esse comportamento também foi confirmado pelos resultados apresentados na Figura 4. As taxas médias obtidas entre

todos os sujeitos variaram de 46,53% com 1 músculo a 78,47% com 5 músculos que foi o melhor resultado, o que está consistente com os valores anteriormente apresentados.

Já em [8] os dedos exerceram pressão sobre uma superfície e foram utilizados 8 eletrodos em uma disposição parecida com a utilizada neste trabalho. As taxas de classificação variaram de 61,4% para o dedo anular a 83,7% para o dedo médio. Neste caso, não houve nenhum processo de otimização de canais. Os resultados contradizem um pouco o que foi apresentado no presente trabalho, uma vez que o dedo anular foi o mais facilmente reconhecido. Mas como os movimentos foram diferentes, isto pode justificar essa inconsistência.

Por outro lado, é interessante notar que, os autores de [7-8] relataram um alto índice de erro no reconhecimento da posição neutra, o que está condizente com o verificado neste trabalho. Apesar de ser uma posição completamente diferente já que todos os dedos estão estendidos, muito provavelmente o baixo nível de tensão muscular desenvolvido nesta posição dificulta a caracterização e conseqüentemente o reconhecimento.

Em [9] apenas o sinal mioelétrico do flexor superficial dos dedos foi considerado para investigar a posição de flexão de cada dedo, obtendo taxas médias de classificação acima de 94,25%. Esta taxa foi superior à apresentada neste trabalho, mas deve-se levar em consideração que não foi considerada a posição neutra nem o movimento do polegar. É sabido que um número menor de classes resulta em taxas de classificação maiores.

No outro extremo, os trabalhos [4] e [5] utilizaram até 32 conjuntos de eletrodos, para investigar não apenas o movimento individual dos dedos, mas também combinações entre eles, totalizando até 12 movimentos. As taxas médias de classificação, excluindo as classes de combinações de movimentos foram de 92,3%. Essas taxas foram mais altas, mas o número de eletrodos utilizados foi consideravelmente maior. E não houve diferença significativa entre as taxas obtidas com 32 e 19 conjuntos de eletrodos. E apesar de [7] ter sinalizado que a partir de uma combinação de 4 músculos as taxas de classificação ficaram constantes, o número total de músculos avaliados foi 8. A diferença (de 8 para 19) é muito grande para o comportamento poder ser generalizado. É plausível acreditar que o classificador recebeu informação relevante que resultou em índices de classificação superiores, mas para ser conclusiva uma investigação maior deve ser feita.

Conclusão

Este trabalho mostrou que para o reconhecimento da posição de flexão individual dos dedos as configurações musculares ideais variam para cada dedo e para cada sujeito, não havendo um padrão geral. A taxa média de classificação foi de 78,47% ocorrendo para configurações com 5 músculos. O dedo anular foi o mais facilmente reconhecido entre os dedos, enquanto a

posição neutra foi a que teve maior erro de classificação.

Tendo em vista a importância do movimento dos dedos na restauração de padrões de preensão para o desenvolvimento de próteses e exoesqueletos de membros superiores, este trabalho apresentou uma contribuição significativa. Mas ainda há muito que fazer como a investigação de outras características do sinal mioelétrico e a aplicação de outras técnicas de classificação, que viabilizem o aumento dos índices de classificação bem como o estudo de movimentos conjuntos dos dedos.

Agradecimentos

Os autores agradecem à FEI e ao CNPq pelo financiamento do projeto através de bolsa PBIC-78/11 e à FAPESP.

Referências

- [1] Herr, H. (2009) “Exoskeletons and orthoses: classification, design challenges and future directions” *Journal of NeuroEngineering and Rehabilitation*, v. 6:21, Doi: [10.1186/1743-0003-6-21](https://doi.org/10.1186/1743-0003-6-21) Acessado em Maio 2012.
- [2] Lake, C., Dodson, R. “Progressive Upper Limb Prosthetics” *Physical Medicine and Rehabilitation Clinics of North America*, v. 17, p. 49–72.
- [3] Sensinger, J., Pasquina, P. F., Kuiken, T. (2009) “The Future of Artificial Limbs” In: *Care of the Combat Amputee*, Ed. Lenhart, M. K., Washington, DC, cap. 27, p. 721-730.
- [4] Tenore, F., Ramos, A., Fahmy, A., Acharya, S., Etienne-Cummings, R. Thakor, N. V., (2007) “Towards the Control of Individual Fingers of a Prosthetic Hand Using Surface EMG Signal”, In: *Proceedings of the 29th Annual International Conference of the IEEE EMBS*, Lyon, France p. 6145-6148. Doi: [10.1109/IEMBS.2007.4353752](https://doi.org/10.1109/IEMBS.2007.4353752) Acessado em Out. 2011.
- [5] Tenore, F., Ramos, A., Fahmy, A., Acharya, S., Etienne-Cummings, R. Thakor, N. V., (2009) “Decoding of Individuated Finger Movements Using Surface Electromyography” *IEEE Transactions on Biomedical Engineering*, v. 56, n. 5, p. 1427-1434.
- [6] Smith, R. J., Huberdeau, D., Tenore, F., Thakor, N. V., (2009) “Real-Time Myoelectric Decoding of Individual Finger Movements For a Virtual Target Task” In: *Proceedings of the 31st Annual International Conference of the IEEE EMBS*, Minneapolis, USA, p. 2376-2379.
- [7] Andrews, A., Morin, E., McLean, L. (2009) “Optimal Electrode Configurations for Finger Movement Classification using EMG” In: *Proceedings of the 31st Annual International Conference of the IEEE EMBS*, Minneapolis, USA, p. 2987-2990.
- [8] Ishikawa, K., Toda, M., Sakurazawa, S., Akita, J., Kondo, K., Nakamura, Y., (2010) “Finger Motion Classification Using Surface-electromyogram Signals”, In: *Proceedings of the 9th IEEE/ACIS International Conference on Computer Information Science*, Kaminoyama, Japan, p. 37-42, Doi: [10.1109/ICIS.2010.131](https://doi.org/10.1109/ICIS.2010.131). Acessado em: Out. 2011.
- [9] Singh, V. P., Kumar, D. K. (2008) “Classification of low-level finger contraction from single channel Surface EMG” In: *Proceedings of the 30th Annual International Conference of the IEEE EMBS*, Vancouver, Canada, p. 2900-2903.
- [10] Hargrove, L. J., Li, G., Englehart, K. B., Hudgins, B. S., (2009) “Principal components analysis preprocessing for improved classification accuracies in pattern-recognition-based myoelectric control” *IEEE Transactions on Biomedical Engineering*, v. 56, n. 5, p. 1407-1414.
- [11] Peleg, D., Braiman, E., (2001) “Classification of Finger Activation using Genetic Algorithm EMG Feature Selection”, *Technical Report*, Department of Electrical Engineering, Israel Institute of Technology, Disponível em: <http://pspl.technion.ac.il/projects/2001w01/docs/book/EMGnew.doc> Acessado em Out. 2011.
- [12] Naik, G. R., Kumar, D. K., Arjunan, S. P., (2010) “Independent Component Analysis For Classification Of Surface Electromyography Signals During Different MVCs” In: *Proceedings of the 20th International EURASIP Conference - BIOSIGNAL 2010: Analysis of Biomedical Signals and Images*, Brno, Czech Republic, p. 352-358.
- [13] Bosco, G. (2010) “Principal Component Analysis of Electromyographic Signals: An Overview” *The Open Rehabilitation Journal*, v. 3, p. 127-131.
- [14] Oliveira, D. P., Nascimento, T. H., Castro, M. C. F. (2010) “Aplicação da Análise de Componentes Principais em Sinais Mioelétricos do Biceps Braquial e Triceps Braquial” In: *Proceedings of the XXII CBEB - Congresso Brasileiro de Engenharia Biomédica*, 2010, Tiradentes, p.154 – 157.
- [15] Castro, M. C. F. (2011) “Statistical Approach for Angular Position Separability Classes of EMG Data” In: *Proceedings of the ISSNIP Biosignals and Biorobotics Conference*, Vitória – ES, Brasil, Doi: [10.1109/BRC.2011.5740663](https://doi.org/10.1109/BRC.2011.5740663) . Acessado em Dez. 2011.
- [16] Castro, M. C. F., (2012) “Linear Discriminant Analysis versus Artificial Neural Network As Classifier for Elbow Angular Position recognition Purposes” In: *Proceedings of the Biosignals 2012 - International Conference on Bio-inspired Systems and Signal Processing*, Vilamoura, Portugal.