

CLASSIFICAÇÃO DE MOVIMENTOS EM SINAIS DE ELETROMIOGRAMA UTILIZANDO ESTATÍSTICA DE ORDEM SUPERIOR

ERIC F. SCHMIELE*, BRUNO H. G. BARBOSA*, DANTON D. FERREIRA*

**Departamento de Engenharia, Universidade Federal de Lavras
Câmpus Universitário, Caixa Postal 3037, CEP 37200-000, Lavras, MG, Brasil*

Emails: eric.schmiele@engautomacao.ufla.br, bruno@deg.ufla.br, danton@deg.ufla.br

Abstract— Electromyogram (EMG) signal analysis has been largely explored through many years to classify muscle nerve oriented movements to then reproduce them with a robotic prostheses. For this, the extraction of diverse information and features from the EMG signal is necessary, such as: RMS value; mean absolute value; among others. These features are fed to a classifying algorithm, such as: Artificial Neural Networks; Support Vector Machine; among others. This study propose the use of Higher Order Statistics (HOS) for the extraction of *cumulants* as features from a dataset with EMG signals previously acquired, genetic algorithm to determine which features are better for the classification, and Linear Discriminant Analysis (LDA) as the classifier algorithm. The proposed feature extraction approach (HOS) achieved better results comparing to the use of common features usually used for EMG classification, and can become even better when using them together.

Keywords— Electromyogram, Robotic Prostheses, Cumulants, Classifying Algorithms, LDA.

Resumo— A análise de sinais de Eletromiograma (EMG) tem sido largamente explorada há muitos anos com o intuito de classificar os movimentos ordenados pelos nervos musculares para efetuá-los utilizando uma prótese robótica. Para tais classificações, é necessária a extração de informações e parâmetros diversos do sinal de EMG, como: valor RMS; média absoluta; entre outros. Estes parâmetros são fornecidos a algum algoritmo de classificação, como: redes neurais artificiais; máquina de vetores de suporte; entre outros. Este estudo propõe o uso de Estatísticas de Ordem Superior (EOS) para a extração de cumulantes como parâmetros de um banco de dados com sinais de EMG previamente fornecidos, algoritmo genético para determinação de quais são os melhores parâmetros para a classificação, e Análise Discriminante Linear (LDA) para a classificação dos dados. Comparando com o uso de parâmetros simples geralmente utilizados para classificação de EMGs, os resultados sugerem que a abordagem proposta tem resultados melhores e pode melhorar ainda mais se utilizada em conjunto.

Palavras-chave— Eletromiograma, Prótese Robótica, Cumulantes, Algoritmos de Classificação, LDA.

1 Introdução

Eletromiograma (EMG) é a leitura de campos elétricos causados pela ativação de músculos e grupos musculares. Como estes campos elétricos são formados por potenciais de ação nas diferentes membranas dos músculos, suas propriedades de onda (frequência, amplitude, etc) estão relacionadas às propriedades destas (Binder et al., 2009). Portanto, é possível extrair informações que podem ser utilizadas para classificar qual movimento está sendo gerado (assim como sua força e velocidade). Por estas e outras razões, EMG tem sido largamente utilizado ao longo dos anos para a classificação de movimentos para próteses robóticas (Parker and Scott, 1986).

O EMG pode ser adquirido utilizando eletrodos na superfície da pele do voluntário (EMG de superfície) ou internamente (EMG interno). EMG interno possui sinais com menos ruídos e mais específicos de um determinado músculo, porém não são largamente explorados para o acionamento de próteses por serem processos invasivos. Alguns pesquisadores exploraram a possibilidade de utilizá-los no acionamento de próteses, porém não há uma diferença significativa nos resultados (Fang et al., 2015).

EMG de superfície é largamente utilizado para o acionamento de próteses, porém é alta-




Figura 1: Exemplo de sinal de EMG amplificado utilizado neste estudo (movimento de fechamento de mão).

mente susceptível a ruídos devido a movimentação de eletrodos, diferença de composição e espessura de pele, além de diferenças em sinais causadas por localização diferenciada de eletrodos (Naik et al., 2015) e interferências de outros sinais biológicos.

Além disso, o sinal de EMG não tem uma forma de onda definida (como apresentado na Figura 1), pois é gerado pelo conjunto dos sinais de potenciais de ação de várias membranas de vários músculos. Por causa de todos estes detalhes, é necessária a extração de informações mais específicas do sinal como um todo.

Dentre os parâmetros utilizados para extra-

ção de informações podem ser citados vários que já foram utilizados em outros estudos como: valor RMS (Amsuess et al., 2015), *wavelet packet transform* (Chu et al., 2006), *SDICA* (Naik et al., 2015), *sample entropy* (Phinyomark et al., 2013), *skewness* e *kurtosis* (Sapsanis et al., 2013), entre outras (Phinyomark et al., 2013). Porém, os mais utilizados são *mean absolute value* (MAV), *zero crossing* (ZC), *slope sign change* (SSC) e *waveform length* (WL) (Englehart and Hudgins, 2003; Chan et al., 2000; Sapsanis et al., 2013). Ainda assim, vários estudos têm tentado utilizar novos parâmetros para a classificação de movimentos.

Estes parâmetros são, então, utilizados em algoritmos de classificação. Estes também diferem grandemente entre os vários estudos: *Multilayer Perceptron*, *K-Nearest Neighbour*, *Lógica Fuzzy*, entre outros (Phinyomark et al., 2013). Vários outros algoritmos já foram considerados, mas como o acionamento de uma prótese deve ser feito rapidamente, os algoritmos com classificação rápida são preferíveis.

Neste estudo, foi proposto utilizar o algoritmo de *Linear Discriminant Analysis* como classificador, por ter uma classificação rápida e por ter sido utilizado com sucesso em outros estudos (Englehart and Hudgins, 2003; Scheme and Englehart, 2011; Phinyomark et al., 2013; Sapsanis et al., 2013).

Para extração de informações foi decidido utilizar Estatísticas de Ordem Superior (EOS), uma vez que é uma extração de dados simples e que exige baixo custo computacional, além de ter mostrado bons resultados em outras áreas de classificação (Naves et al., 2016).

2 Materiais e Métodos

A sequência de etapas para a classificação é apresentada na Figura 2. Em seguida cada etapa é apresentada individualmente.

2.1 Sinais do Banco de Dados

O banco de dados utilizado foi gerado por Sapsanis et al. (2013) contendo sinais de EMG para classificação de movimentos básicos da mão. Este possui leituras de EMG utilizando dois eletrodos nos músculos flexor ulnar do carpo e extensor radial curto e longo do carpo, coletados com uma frequência de amostragem de 500Hz com filtro passa faixa com frequências de corte alta e baixa




Figura 2: Etapas geralmente empregadas para classificação de dados utilizando técnicas de reconhecimento de padrões.




Figura 3: Classes de movimentos de mão utilizados neste estudo.

de 500Hz e 15Hz respectivamente. Além de um filtro *notch* na frequência de 50Hz para eliminar interferências de linha.

Os sinais foram retirados de cinco voluntários saudáveis (três mulheres e dois homens com idade entre 20 e 22 anos) que efetuaram seis tipos de movimento, trinta vezes para cada movimento (Sapsanis et al., 2013). Os movimentos foram classificados como Cilíndrico (C), Gancho (H), Lateral (L), Palmar (P), Esférico (S) e Ponta (T), como apresentado na Figura 3.

Os sinais de EMG deste banco de dados já foram separados com apenas a leitura do movimento, não sendo necessário verificar se há movimento ou não, geralmente feito através de uma análise do valor da média absoluta (Phinyomark et al., 2013).

Como a classificação e atuação de uma prótese deve ser concluída dentro de 300ms - do contrário o usuário perceberá o atraso no movimento, e considerará o desempenho da prótese como insatisfatória (Englehart and Hudgins, 2003) - foi considerada uma janela móvel de observação de dados de 250ms de extensão (vetor com 125 pontos de observação segundo a frequência de amostragem) e 150ms de passo, segundo (Scheme and Englehart, 2011). Assim, os primeiros 100ms da segunda janela correspondem aos últimos 100ms da primeira janela e assim por diante, como apresentado na Figura 4. Como o sinal possui uma duração de 6s, foram retirados parâmetros de 39 janelas para cada movimento.

Ao todo são 39 janelas para cada sinal, totalizando 1170 para todos os movimentos de uma mesma classe e um mesmo indivíduo, assim, obtendo 7020 janelas para cada voluntário.

2.2 Extração de parâmetros do sinal

Neste estudo, foram utilizados como parâmetros cumulantes de segunda, terceira e quarta ordens. Estes são extraídos de um sinal utilizando EOS, consideradas como adequadas para lidar com processos não Gaussianos e sistemas não lineares




Figura 4: Janelas de dados (Azul: canal 1 do sinal de EMG; Vermelho: canal 2 do sinal de EMG; Preto: Janela 1; Verde: Janela 2; Ciano: Janela 3; Magenta: Janela 4).

(Mendel, 1991).

Assim, sendo $X(t)$ um processo aleat rio com um conjunto de vari veis aleat rias $(x_1, x_2, \dots, x_n)$, para vari veis aleat rias reais com m dia zero, os cumulantes de segunda terceira e quarta ordens s o dados por (Mendel, 1991):

$$\begin{aligned} cum(x_1, x_2) &= E(x_1 x_2), \\ cum(x_1, x_2, x_3) &= E(x_1 x_2 x_3) \\ cum(x_1, x_2, x_3, x_4) &= E(x_1 x_2 x_3 x_4) \\ &\quad - E(x_1 x_2)E(x_3 x_4) \\ &\quad - E(x_1 x_3)E(x_2 x_4) \\ &\quad - E(x_1 x_4)E(x_2 x_3), \end{aligned} \quad (1)$$

sendo E o operador de esperan a matem tica.

Supondo $x(t)$, um processo aleat rio estacion rio com m dia zero, os cumulantes de ordem k , denotados por $C_{k,x}(\tau_1, \tau_2, \dots, \tau_k)$, onde $\tau_1, \dots, \tau_k$ s o deslocamentos no tempo, s o definidos em termos dos sinais $x(t)$, $x(t + \tau_1), \dots, x(t + \tau_k)$. Definindo $\tau_1 = \tau_2 = \tau_3 = \tau$, os cumulantes de segunda, terceira e quarta ordens podem ser expressos por

$$\begin{aligned} C_{2,x}(\tau) &= E\{x(t)x(t + \tau)\}, \\ C_{3,x}(\tau) &= E\{x(t)x^2(t + \tau)\}, \\ C_{4,x}(\tau) &= E\{x(t)x^3(t + \tau)\} - 3C_{2,x}(\tau)C_{2,x}(0). \end{aligned} \quad (2)$$

Para um sinal discreto $x[n]$, (2) pode ser aproximado utilizando a forma circular de c culo dos cumulantes proposta em (Ribeiro et al., 2007).

$$\begin{aligned} C_{2,x}(\tau) &= \frac{1}{N} \sum_{n=0}^{N-1} x[n]x[\text{mod}(n + \tau, N)], \\ C_{3,x}(\tau) &= \frac{1}{N} \sum_{n=0}^{N-1} x[n]x^2[\text{mod}(n + \tau, N)], \\ C_{4,x}(\tau) &= \frac{1}{N} \sum_{n=0}^{N-1} x[n]x^3[\text{mod}(n + \tau, N)] \\ &\quad - 3 \frac{1}{N} \sum_{n=0}^{N-1} x[n]x[\text{mod}(n + \tau, N)] \cdot \sum_{n=0}^{N-1} x^2[n], \end{aligned} \quad (3)$$

sendo $x \in \mathbb{R}^N$ e $\tau = 0, 1, \dots, N - 1$, em que mod   o operador de m dulo (resto da divis o de n mero inteiro).

Al m de cumulantes, os par metros simples: *Mean Absolute Value* (MAV), *Zero Crossing* (ZC), *Slope Sign Change* (SSC) e *Waveform Length* (WL) tamb m foram extra dos e colocados em um vetor separado para compara  o com os resultados de outros estudos (Englehart and Hudgins, 2003; Sapsanis et al., 2013) e para verificar a possibilidade de utiliz -los de maneira conjunta com os cumulantes.

Estes par metros s o obtidos segundo as seguintes equa  es:

$$MAV = \frac{1}{N} \sum_{k=1}^N \|x_k\|, \quad (4)$$

$$ZC = \begin{cases} 1, & \text{se } (x_k > 0 \ \& \ x_{k+1} < 0) \\ & \text{OU } (x_k < 0 \ \& \ x_{k+1} > 0), \\ & k = 1, 2, \dots, N - 1 \\ 0, & \text{caso contr rio} \end{cases}, \quad (5)$$

$$SSC = \begin{cases} 1, & \text{se } (x_k < x_{k+1} \ \& \ x_k < x_{k-1}) \\ & \text{OU } (x_k > x_{k+1} \ \& \ x_k > x_{k-1}), \\ & k = 1, 2, \dots, N - 1 \\ 0, & \text{caso contr rio} \end{cases}, \quad (6)$$

$$WL = \sum_{k=1}^{N-1} (\|x_{k+1} - x_k\|). \quad (7)$$

sendo x o conjunto de dados de um sinal e N o n mero total de amostras deste sinal.

2.3 Redu  o de Dimens o

Ap s a extra  o dos par metros simples e dos cumulantes, foram obtidos dois vetores para cada evento de movimento. Um com os par metros simples tendo 8 posi  es (quatro para cada canal de EMG), e outro com os cumulantes tendo 624 posi  es (62 de segunda ordem, 125 de terceira ordem e 125 de quarta ordem para cada canal de EMG). Como o n mero de cumulantes   muito grande,   necess ria a utiliza  o de um algoritmo para redu  o de dimens o. Uma vez que h  a possibilidade de se obter uma boa classifica  o utilizando apenas alguns dos cumulantes, o que reduzir  o custo computacional da classifica  o.

Para tal, foi utilizado um Algoritmo Gen tico (AG), possibilitando uma escolha de cumulantes de forma que a classifica  o tenha um melhor desempenho.

Os Algoritmos Gen ticos s o uma classe de algoritmos pertencentes ao ramo dos algoritmos evolucion rios e t m por objetivo buscar uma solu  o  tima para o problema proposto manipulando uma popula  o de solu   es candidatas (Fix and Hodges, 1951). A Figura 2.3 ilustra o fluxo-grama b sico de implementa  o de AGs.




Figura 5: Fluxograma de atividades de um AG básico.

Assim, o AG é utilizado neste estudo para minimizar uma equação de custo composta pelo erro de classificação e o número de cumulantes utilizados na classificação. Cada indivíduo consiste de um vetor binário de 312 posições para determinar se um cumulante do canal 1 e do canal 2 está sendo utilizado ou não. Desta maneira, se a posição 20 tiver valor 1, significa que as posições 20 e 342 do vetor de cumulantes serão utilizadas (pois uma parte do sinal do canal 1 não pode ser avaliada sem que esta parte do canal 2 também seja avaliada). Para o caso de utilizar os parâmetros simples em conjunto com os cumulantes, o vetor binário possui 316 posições. Uma posição a mais para cada parâmetro simples (considerando que se um parâmetro do canal 1 for utilizado, é necessário utilizar o mesmo parâmetro do canal 2 também).

A avaliação de cada indivíduo é dada por:

$$\text{Avaliação} = Er + 0,001N_c, \quad (8)$$

onde Er é o erro de classificação (em porcentagem) do indivíduo avaliado, e N_c é o número de cumulantes utilizados pelo indivíduo avaliado. Esta última variável é utilizada para minimizar o número de cumulantes utilizados na classificação. Portanto, no caso de dois indivíduos apresentarem o mesmo erro de classificação, aquele que apresentar o menor número de cumulantes terá melhor avaliação.

2.4 Classificação

Considerando a classificação de sinais de EMG, vários estudos utilizaram diferentes algoritmos, como redes neurais artificiais, máquina de vetores de suporte, lógica fuzzy entre outros. Porém, segundo Phinyomark et al. (2013), um dos melhores classificadores para este estudo é o *Linear Discriminant Analysis* (LDA). Portanto, este foi o algoritmo utilizado neste estudo.

LDA procura pelos vetores que mais se diferenciam entre as classes. Isto é, dado um número de características individuais pelos quais os dados são descritos, LDA cria uma combinação linear dos que apresentam maior diferença entre as classes desejadas (Martínez and Kak, 2001). Criando assim um padrão de classificação para o conjunto de dados apresentado.

Após separadas as janelas dos sinais originais, os parâmetros simples e os cumulantes foram extraídos de cada uma destas em diferentes vetores. Estes vetores foram, então, separados: 70% deles foram utilizados para o treino do algoritmo classificador enquanto os outros 30% foram utilizados para a validação dos resultados de treino.

Cada teste utilizou apenas dados de um voluntário de cada vez, uma vez que os sinais de EMG diferem grandemente entre uma pessoa e outra sem contar com as diferenças causadas por posicionamento diferente de eletrodos (Naik et al., 2015). Sendo assim, para cada indivíduo foram efetuados 16 testes de classificações com os vetores de parâmetros simples e outros 16 testes com os vetores de cumulantes, sendo que, em cada teste, os vetores de validação foram escolhidos aleatoriamente.

Para os testes com vetores de parâmetros simples, foi utilizado apenas o algoritmo de classificação (LDA) para treino e para validação logo em seguida, uma vez que não havia necessidade de redução de dimensão neste caso. Para os testes com vetores de cumulantes, foi utilizado o algoritmo de redução. Este treina várias possibilidades de combinações dos cumulantes (redução de dimensão) para, então, determinar qual dentre elas é a melhor. Uma vez que a melhor combinação é encontrada, o algoritmo de classificação é utilizado no grupo de validação.

Todos estes testes foram realizados utilizando o software MATLAB® em computadores HP Core2 Quad 2.66GHz com 4Gb de RAM.

3 Resultados e Discussões

Considerando a área de acionamento de próteses, um classificador com 85% de acerto é considerado bom (Englehart and Hudgins, 2003). Seguindo esta análise, os resultados obtidos utilizando apenas os parâmetros simples não foram satisfatórios, conforme apresentado na Tabela 1. Assim, outros 16 testes foram realizados, desta vez, utilizando os parâmetros simples e os cumulantes (vetores com 632 posições). Estes foram efetuados da mesma maneira que os testes com vetores de cumulantes e apresentaram porcentagens de acerto satisfatórias, também apresentadas na Tabela 1, além de demonstrar uma ótima classificação para algumas das seis classes (C, P e T), como é possível ver na matriz de confusão apresentada na Tabela 2.

Também foi efetuada uma análise estatística

Tabela 1: Porcentagem de acerto dos testes de classificação de todos os voluntários considerando treino e validação.

Voluntário	Dados	Parâmetros simples	Cumulantes	Cumulantes e parâmetros simples
Mulher 1	Treino	76,72	78,11	82,21
	Validação	76,75	72,51	77,86
Mulher 2	Treino	63,93	70,85	77,45
	Validação	63,63	65,84	73,62
Mulher 3	Treino	73,87	76,53	79,07
	Validação	73,83	71,51	75,91
Homem 1	Treino	77,93	80,25	83,81
	Validação	77,61	76,97	81,42
Homem 2	Treino	83,95	85,68	92,02
	Validação	83,81	82,18	89,50

Tabela 2: Matriz de Confusão para o caso de classificação dos dados do Homem 2 utilizando cumulantes e parâmetros simples.

		Valores Classificados					
		C	H	L	P	S	T
Valores Reais	C	1108	1	0	0	2	59
	H	55	901	210	0	0	4
	L	6	63	1038	1	0	62
	P	3	1	0	1166	0	0
	S	13	1	1	48	1106	1
	T	15	0	3	2	0	1150

utilizando o Teste de Tukey, o qual comprovou que os testes também foram estatisticamente melhores (95% de confiança), uma vez que não há sobreposição de intervalos entre os três casos (Figura 6).




Figura 6: Resultados do Teste de Tukey - 95% de confiança (1-Azul: Teste com parâmetros simples; 2-Vermelho: Teste com cumulantes; 3-Verde: Teste com cumulantes e parâmetros simples).

É importante ressaltar que no caso com apenas cumulantes, foram utilizados 175 cumulantes em média, com 34 de segunda ordem, 71 de terceira ordem e 70 de quarta ordem. E, nos casos de parâmetros simples com cumulantes, todos os parâmetros simples foram utilizados, e 170 cumulantes foram utilizados em média, com 35 de segunda ordem, 68 de terceira ordem e 67 de quarta ordem. Portanto, é necessária a utilização de apenas 50% dos cumulantes para obter uma boa classificação, um bom resultado de redução de dimensão.

Mesmo obtendo um resultado satisfatório, não

foram todas as classificações que ultrapassaram 90% de acerto (considerado mínimo segundo Englehart and Hudgins (2003)). Sapsanis et al. (2013) conseguiram resultados em média melhores do que os deste estudo (a média de acerto foi maior, porém o desvio padrão foi muito maior) utilizando o mesmo banco de dados, porém utilizando os mesmos parâmetros simples em conjunto com alguns outros, e utilizando diferentes algoritmos de redução e classificação. Englehart and Hudgins (2003) utilizaram os mesmos parâmetros simples e o mesmo algoritmo de classificação, porém utilizou um banco de dados com quatro canais de EMG e com uma frequência de amostragem de 1kHz, classificado em apenas quatro classes, obtendo uma média de 94% de acerto na classificação.

4 Conclusão

Este estudo apresentou um novo conjunto de parâmetros a serem utilizados na classificação de movimentos para acionamento de próteses robóticas para mão. A proposta foi de utilizar parâmetros extraídos por meio de técnicas de EOS (cumulantes) em conjunto com AG para redução de dimensionalidade e LDA como classificador.

Foi utilizado um banco de dados com sinais referentes a seis diferentes movimentos, os quais foram classificados utilizando o esquema proposto. E testes utilizando parâmetros simples anteriormente comprovados como bons para a classificação também foram efetuados, para provar a confiabilidade dos resultados.

Os resultados de treino utilizando cumulantes apresentaram um desempenho melhor, porém os resultados de validação utilizando parâmetros simples ainda foram melhores que os utilizando cumulantes. Por esta razão, também foram efetuados testes com os parâmetros simples em conjunto com os cumulantes. Estes apresentaram melhores resultados tanto em treino quanto em validação.

Comparando com outros estudos, a abordagem proposta neste trabalho é promissora, porém

ainda necessita de investigações mais detalhadas. A utilização de um novo banco de dados pode ser necessária. Este deve conter: sinais de EMG com quatro canais (Naik et al., 2015); frequência de amostragem de 1kHz para evitar efeitos de *aliasing* ao considerar os mesmos filtros empregados (Amsuess et al., 2015; Chan et al., 2000); dados extraídos em vários dias diferentes para promover a robustez do classificador (Phinyomark et al., 2013). Também podem ser considerados em conjunto outros parâmetros e outros algoritmos classificadores, como os apresentados por Phinyomark et al. (2013).

Sendo assim, é possível concluir que o estudo obteve bons resultados, com a possibilidade de melhoria em estudos futuros. E, por utilizar parâmetros que são facilmente adquiridos e um classificador simples, tem o potencial para acionar próteses com microcontroladores simples, possibilitando a manufatura de uma prótese mais simples e barata.

Agradecimentos

Agradecimento à UFLA (Universidade Federal de Lavras) por possibilitar o acesso ao laboratório de processamento de sinais do Departamento de Engenharia. E à FAPEMIG (Fundação de Amparo à Pesquisa de MG) por possibilitar este Projeto de Iniciação Científica.

Referências

- Amsuess, S., Goebel, P., Graimann, B. and Farina, D. (2015). A Multi-Class Proportional Myocontrol Algorithm for Upper Limb Prosthesis Control: Validation in Real-Life Scenarios on Amputees, *IEEE Transactions on Neural Systems and Rehabilitation Engineering* **23**(5): 827–836.
- Binder, M. D., Hirokawa, N. and Windhorst, U. (2009). *Encyclopedia of Neuroscience*, 1 edn, Springer.
- Chan, F. H. Y., Yang, Y.-S., Lam, F. K., Zhang, Y.-T. and Parker, P. A. (2000). Fuzzy EMG Classification for Prosthesis Control, *Transactions on Rehabilitation Engineering* **8**(3): 305–311.
- Chu, J.-U., Moon, I. and 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* **53**(11): 2232–2239.
- Englehart, K. and Hudgins, B. (2003). A Robust, Real-Time Control Scheme for Multifunction Myoelectric Control, *IEEE Transactions on Biomedical Engineering* **50**(7): 848–854.
- Fang, Y., Hattiarachchi, N., Zhou, D. and Liu, H. (2015). Multi-Modal Sensing Techniques for Interfacing Hand Prostheses: A Review, *IEEE Sensor Journal* **15**(11): 6065–6076.
- Fix, E. and Hodges, J. L. (1951). Discriminatory analysis, nonparametric discrimination: Consistency properties, *USAF School of Aviation Medicine*, Randolph Field, Texas.
- Martínez, A. M. and Kak, A. C. (2001). PCA versus LDA, *IEEE Transactions on Pattern Analysis and Machine Intelligence* **23**(2): 228–233.
- Mendel, J. M. (1991). Tutorial on Higher-Order Statistics (Spectra) In Signal Processing and System Theory: Theoretical Results and Some Applications, *Proc. IEEE* **79**: 278–305.
- Naik, G. R., Baker, K. G. and Nguyen, H. T. (2015). Dependence Independence Measure for Posterior and Anterior EMG Sensors Used in Simple and Complex Finger Flexion Movements: Evaluation Using SDICA, *IEEE Journal of Biomedical and Health Informatics* **19**(5): 1689–1696.
- Naves, R., Barbosa, B. H. G. and Ferreira, D. D. (2016). Classification of Lung Sounds using Higher-Order Statistics: A divide-and-conquer approach, *Computer Methods and Programs in Biomedicine (Print)* **129**: 12–20.
- Parker, P. A. and Scott, R. N. (1986). Myoelectric control of prostheses, *Critical Reviews in Biomedical Engineering* **13**: 283–310.
- Phinyomark, A., Quaine, F., Charbonnier, S., Service, C., Tarpin-Bernard, F. and Laurillau, Y. (2013). EMG feature evaluation for improving myoelectric pattern recognition robustness, *Expert Systems with Applications* **40**: 4832–4840.
- Ribeiro, M. V., Marques, C. A., Duque, C. A., Cerqueira, A. S. and Pereira, J. L. R. (2007). Detection of Disturbances in Voltage Signals for Power Quality Analysis Using HOS, *EURASIP Journal on Advances in Signal Processing*.
- Sapsanis, C., Georgoulas, G. and Tzes, A. (2013). EMG based classification of basic hand movements based on timefrequency features, *21st Mediterranean Conference on Control & Automation (MED)*, Platania-Chania, Crete, Greece, pp. 716–722.
- Scheme, E. and Englehart, K. (2011). Electromyogram pattern recognition for control of powered upper-limb prostheses: State of the art and challenges for clinical use, *Journal of Rehabilitation Research & Development* **48**(6): 643–659.