

SINAIS DE SEMG APLICADOS NA CLASSIFICAÇÃO DE MOVIMENTOS DE MEMBROS SUPERIORES

AMANDA FERNANDES VILAÇA MARTINS*, KESSIA KLEIN PEREIRA*, DANIEL CRUZ CAVALIERI*,
FLÁVIO GARCIA PEREIRA*

**Instituto Federal de Educação, Ciência e Tecnologia do Espírito Santo – IFES campus Serra
Rodovia ES-010 – km 6,5 – Manginhos – Serra – ES. CEP 29173-087*

Emails: amanda.fvmartins@gmail.com, kessiakp@gmail.com, daniel.cavaliere@ifes.edu.br,
flavio.garcia@ifes.edu.br

Abstract— This work consists of the development of a SVM-based algorithm to classify six predefined movements of upper limbs, performed by healthy volunteers, using surface electromyography signals (sEMG). The proposed project falls within the context of the development of interfaces for application in robotic devices, whose purpose is the motor rehabilitation adapting control of these devices according to user's intent. The main purpose of this work is to determine the movement intention through muscle activation analysis and the effective beginning of the performed movements. Biological signal processing techniques were used for this classification, where eleven time-domain features were extracted from the signal, and system classification techniques. The results show that the proposed algorithm, despite using using an inferior amount of training data, achieved a percentage of 82.44% of accuracy, when compared to other works of literature, which obtained a percentage of 87.70% of accuracy. This shows that the methodology adopted in this work was successful under the studied conditions.

Keywords— Electromyography Signals Surface, Robotic Rehabilitation, Signal Processing.

Resumo— Este trabalho consiste no desenvolvimento de um algoritmo baseado em máquinas de vetor suporte (SVM) capaz de realizar a classificação de seis movimentos pré-definidos dos membros superiores, realizados por voluntários saudáveis, através dos dados de sinais eletromiográficos de superfície (sEMG). O projeto proposto insere-se no contexto do desenvolvimento de interfaces para aplicação em dispositivos robóticos, cujo propósito é a reabilitação motora adaptando o controle destes dispositivos de acordo com a intenção do usuário. O objetivo principal é determinar a intenção do movimento através da análise da ativação muscular e do início efetivo dos movimentos realizados. Foram utilizadas, para isso, técnicas de processamento de sinais biológicos, onde foram extraídas onze características no domínio do tempo, e técnicas de classificação de sistemas. Os resultados apresentados demonstram que, mesmo utilizando uma quantidade inferior de dados de treinamento, o algoritmo proposto obteve uma porcentagem de 82,44% de acertos contra 87,70% de outro trabalho da literatura. Isso permite concluir que a metodologia adotada neste trabalho de conclusão de curso obteve sucesso para as condições estudadas.

Palavras-chave— Robótica de Reabilitação, Processamento de Sinais Biológicos, Máquinas de Vetor Suporte.

1 Introdução

Os estudos de técnicas de reabilitação motora em pessoas com algum tipo de deficiência têm como principais objetivos restaurar as funções motoras perdidas ou auxiliar no tratamento destas deficiências. Na área da engenharia biomédica, a evolução das contribuições para a reabilitação humana tem sido significativa, causando um grande avanço no que diz respeito aos resultados e a aplicabilidade destas pesquisas (Fleury-Rosa, 2005). De outra maneira, a reabilitação é um processo global e dinâmico orientado para a recuperação física e psicológica da pessoa portadora de deficiência, tendo em vista a sua reintegração social (Gonçalves and Carvalho, 2010).

Visando a melhoria da qualidade de vida dessas pessoas, o desenvolvimento de técnicas de reabilitação tende a contribuir de forma significativa para que as mesmas vivam com mais conforto. Neste contexto, o estudo do comportamento dos músculos ao realizar determinados movimentos é o primeiro passo para o correto desenvolvimento destas técnicas. Os músculos e seus respectivos estímulos possuem características de modelagem

complexa. Portanto, é necessário buscar soluções e experimentar novas técnicas nas áreas de aquisição, reconhecimento e classificação dos sinais mioelétricos musculares, com o intuito de encontrar sistemas mais robustos e confiáveis, de modo a prover maior conforto e comodidade a essas pessoas.

No presente trabalho seis movimentos pré-definidos dos membros superiores adquiridos utilizando-se a técnica de eletrodos não-invasivos serão estudados. Com o sinal muscular de cada movimento será utilizada a metodologia proposta por (Phinyomark et al., 2009) e adaptada aqui. A técnica desenvolvida baseia-se em extrair algumas características específicas do sinal para conseguir estimar a intenção de movimento, a ativação muscular e o início efetivo dos mesmos. No artigo citado os autores utilizam 18 características no domínio do tempo e da frequência, aqui serão utilizadas apenas 11 características e apenas no domínio do tempo.

A fim de se obter resultados robustos, antes da extração de características foi realizada, neste trabalho, uma filtragem no domínio do tempo através

de um filtro de variâncias. Essa filtragem foi inicialmente proposta por (Kirchner et al., 2014) e tem como característica principal uma diferenciação entre os momentos de ativação e não ativação muscular, preservando assim o momento de ativação inicial, ao passo que elimina pequenas variações, como ruídos (da Silveira Araújo et al., 2014).

Com o objetivo de classificar os dados obtidos, utilizou-se um modelo baseado em *Support Vector Machines* (SVM). A SVM é uma técnica de aprendizado de máquina que vem recebendo crescente atenção da comunidade científica (Khan and Hasan, 2015; Alkan and Günay, 2012; Kaur et al., 2009).

2 Referencial Teórico

2.1 O Sinal Eletromiográfico

O sinal eletromiográfico é proveniente do potencial de ação que percorre a fibra muscular levando-a à contração e à extensão. A primeira dedução de que um músculo estaria gerando um potencial elétrico foi documentada pelo italiano Francesco Redi, em 1666, quando suspeitou que o choque de uma enguia elétrica fosse de origem muscular. No entanto, somente em 1838, Carlos Matteucci demonstrou a evidência da atividade elétrica durante a contração muscular, utilizando-se dos primeiros galvanômetro (Andrade, 2007). No entanto, apenas após o surgimento do tubo de raios catódicos, em 1897 por Braun, tornou-se possível estudar a morfologia do sinal elétrico. Herberth S. Gasses e Joseph Erlanger foram os primeiros a apresentar as características do sinal mioelétrico de forma gráfica, utilizando para isso um osciloscópio, o que lhes rendeu o prêmio Nobel em 1944 (Ortolan et al., 2000). A partir de então, a eletromiografia (EMG), que é considerada o estudo das funções musculares através da captação do sinal mioelétrico, começou a utilizar dispositivos para detecção, amplificação e apresentação do EMG de forma gráfica (Cavaliere, 2007). Porém, apenas no final da década de 60 iniciou-se o processamento e estudo do sinal através de computadores, obtendo-se assim, informações mais consistentes do mesmo.

Os sinais eletromiográficos associados a recursos computacionais específicos, nos dias atuais, são utilizados como uma solução largamente estudada para controle de dispositivos utilizados na Engenharia de reabilitação e até mesmo na robótica móvel (Neto et al., 2006).

2.2 Filtragem do Sinal Eletromiográfico Proveniente de Membros Superiores

A maior parte dos sinais biológicos possui baixas amplitudes e são acompanhados de outros sinais de várias origens. Qualquer sinal diferente do sinal

de estudo pode ser caracterizado como interferência, artefato ou simplesmente ruído (Rangayyan, 2015). As fontes de ruídos podem ser fisiológicas, do próprio corpo humano, do instrumento utilizado, ou do ambiente onde se realiza a aquisição de dados. Para o sinal mioelétrico proveniente de membros superiores, as principais fontes de ruídos que interferem na aquisição de dados são: interferência da rede elétrica, ruídos musculares e ruídos provenientes de artefatos de movimentos.

É de extrema importância para um sistema que reconheça o sEMG de membros superiores que o sinal não possua suas características alteradas por distúrbios. Portanto, conhecendo os principais ruídos característicos da aquisição do sinal, é possível aplicar técnicas de filtragem para atenuá-los sem que se altere as características do mesmo. Assim, com a base de dados utilizada no presente trabalho, no pré-processamento do sinal foi realizada uma filtragem no domínio do tempo através do filtro de variâncias, ou seja,

$$v(t) = \frac{1}{N-1} \sum_{i=0}^N [x(t-i)]^2 - \left[\frac{1}{N-1} \sum_{i=0}^{N-1} x(t-i) \right]^2 \quad (1)$$

onde, refere-se ao sinal, N é o tamanho da janela de amostras usada na filtragem e é o sinal sEMG a ser filtrado. Essa filtragem foi proposta por (Kirchner et al., 2014) com uma finalidade semelhante à almejada neste projeto e tem como característica principal uma grande diferenciação entre os momentos de ativação muscular e não ativação, preservando o momento de ativação inicial ao passo que elimina pequenas variações, como os ruídos (da Silveira Araújo et al., 2014).

2.3 Extração de Características do sEMG

A etapa de extração de características de um sinal é fundamental para que seja possível alcançar um bom resultado na classificação. Para isto, uma boa extração das características, distinguindo com clareza e eficiência o repouso, a ativação muscular, suas principais características e valores torna-se imprescindível. Com esse objetivo, após o processamento do sinal serão extraídas onze características no domínio do tempo:

- Integração: a Integração no sinal EMG (IEMG) geralmente, é usado como indicador de início da ativação muscular e pode ser calculado de acordo com a equação 2.

$$IEMG = \sum_{n=1}^N |x_n|, \quad (2)$$

onde N é o comprimento do sinal e x_n representa o sinal sEMG.

- Valor Médio Absoluto (MAV): do inglês, *Mean Absolute Value* é uma forma fácil de detectar a contração muscular em diferentes

níveis e é calculado como mostra a equação 3.

$$MAV = \frac{1}{N} \sum_{n=1}^N |x_n|. \quad (3)$$

- Valor Médio Absoluto Modificado 1 (MMAV1): é uma extensão do valor médio absoluto usando funções de pesos (w_n). É definido como mostra a equação 4.

$$MMAV1 = \frac{1}{N} \sum_{n=1}^N w_n |x_n|, \quad (4)$$

onde $w_n = 1$ se $0,25N \leq n \leq 0,75N$ e $w_n = 0,5$ caso contrário.

- Valor Médio Absoluto Modificado 2 (MMAV2): similar ao MMAV1, entretanto é melhorado neste método usando a função de peso contínua. É indicado pela equação 5.

$$MMAV2 = \frac{1}{N} \sum_{n=1}^N w_n |x_n|, \quad (5)$$

onde $w_n = 1$ caso $0,25N \leq n \leq 0,75N$, $w_n = \frac{4n}{N}$ se $0,25N > n$ e $w_n = \frac{4n - N}{N}$ se $0,75N < n$.

- Integral quadrada simples (SSI): do inglês *Simple Square Integral*, extrai a energia do sinal como característica. Pode ser expressada como na equação 6.

$$SSI = \sum_{n=1}^N |x_n|^2. \quad (6)$$

- Variância (VAR): extrai a potência do sinal como característica. Pode ser calculada como mostra a equação 7.

$$VAR = \frac{1}{N-1} \sum_{n=1}^N |x_n|^2. \quad (7)$$

- Média Quadrática (RMS): do inglês *Root Mean Square*, está relacionada à força constante utilizada para contração muscular. É definida pela equação 8.

$$VAR = \sqrt{\frac{1}{N} \sum_{n=1}^N |x_n|^2}. \quad (8)$$

- Comprimento de Onda Cumulativo no Tempo (WL): é o comprimento de onda cumulativo da forma de onda do sinal durante todo o tempo estudado. Pode ser calculado como mostra a equação 9.

$$WL = \sum_{n=1}^{N-1} |x_{n+1} - x_n|. \quad (9)$$

- Passagem pelo Zero (ZC): é o número de vezes que o valor da amplitude do sEMG atravessa o zero no eixo-x. Utiliza um valor limitador (δ), capaz de retirar parte do ruído existente no sinal. Pode ser calculada como na equação 10.

$$\sum_{n=1}^{N-1} [sign(x_n \times x_{n+1}) \cap |x_{n+1} - x_n| \geq \delta]. \quad (10)$$

- Inclinação na Mudança de Sinal (SSC): número de mudanças do sinal da inclinação entre três segmentos consecutivos é realizado pelo limitador para evitar interferências no sinal. É calculado pela equação 11.

$$SSC = \sum_{n=2}^N [sign[(x_n - x_{n-1}) \times (x_{n+1} - x_n)]]. \quad (11)$$

- Amplitude de Willison (WAMP): calcula o número de vezes que a diferença entre a amplitude do sEMG entre dois segmentos adjacentes excedem um limite pré-definido. Esse cálculo é utilizado para reduzir o ruído e está mostrado na equação 12.

$$WAMP = \sum_{n=1}^{N-1} sign(|x_n - x_{n+1}|). \quad (12)$$

2.4 Suport Vector Machines

O trabalho aqui desenvolvido utiliza um algoritmo baseado em Máquinas de Vetor Suporte (do inglês, *Support Vector Machines*) como classificador dos movimentos de membros superiores apresentados na Figura 2. O SVM consiste em uma técnica de aprendizado para problemas de reconhecimento de padrões. A técnica foi introduzida por (Vapnik, 1995) e vem sendo utilizada com grande sucesso em problemas de diversas naturezas.

Os classificadores SVM representam uma nova abordagem para a classificação de padrões que tem atraído um grande interesse da comunidade de aprendizagem de máquina. Eles operam no princípio da indução de minimização do risco estrutural, o que minimiza um limite superior sobre o erro. Tem demonstrado ser bem sucedido na resolução de diversos problemas de reconhecimento de padrões, possuindo um desempenho superior em algumas situações quando comparados a outros classificadores não lineares (Kaur et al., 2009). A ideia básica do SVM é separar as classes com superfícies que maximizem a margem entre as mesmas, ou seja, encontrar um hiperplano de separação ótima (Souza, 2011). Assim, dado um conjunto de pontos no qual cada um pertence a duas possíveis categorias, um algoritmo baseado em SVM constrói um modelo que prediz se um ponto novo pertence a uma categoria ou à outra. Neste trabalho, para a utilização do classificador SVM foi utilizado o software Matlab®.

3 Metodologia

A metodologia do trabalho consiste, portanto, em três etapas chaves:

1. Processamento do Sinal.
2. Extração das Características.
3. Classificação dos Movimentos.

O banco de dados utilizado para a elaboração deste trabalho pertence a (Sapsanis et al., 2013) e trata-se de um banco de dados de sinais musculares coletados a uma taxa de amostragem de 500 Hz, o hardware utilizado como placa de aquisição foi o NI USB-6009 da National Instruments. O mesmo foi conectado a um computador com o software Labview, também da mesma empresa. Os sinais coletados foram filtrados com um filtro passa banda Butterworth com frequência de corte baixa e alta de 15 Hz e 500 Hz respectivamente. Também foi utilizado um filtro Notch para eliminar a frequência de rede de 50 Hz.

O experimento de coleta de dados consistiu em realizar movimento distintos, essenciais para representar os principais movimentos da mão. A velocidade e força foram intencionalmente deixados à vontade do voluntário. Dois eletrodos EMG de superfície foram instalados no antebraço, nos músculos Flexor Ulnar do Carpo e Extensor Radial longo do Carpo, como mostrado na Figura 1.




Figura 1: Localização dos eletrodos.

Aos voluntários, cinco pessoas saudáveis sendo: dois homens e três mulheres, com aproximadamente a mesma idade (entre 20 e 22 anos), foi pedido para realizar seis movimentos por 30 vezes cada. Os mesmos são descritos a seguir e mostrados na Figura 2.

Os movimentos são: (a) *Cylindrical*: pressionar um objeto cilíndrico, (b) *Tip*: pressionar um objeto pequeno entre as ponta dos dedos indicador e polegar, (c) *Hook*: carregar uma carga pesada, (d) *Palmar*: pressionar um objeto com a palma da mão voltada para o mesmo, (e) *Spherical*: pressionar um objeto fino e esférico e (f) *Lateral*: pressionar um objeto plano e fino com a mão fechada entre os dedos indicador e polegar.

Primeiramente, é feita a filtragem através do filtro de variâncias, onde foi possível visualizar os momentos de ativação muscular e reduzir a quantidade de ruídos, assim como descrito no item 2.2. Para esta e todas as etapas seguintes da metodologia o software utilizado foi o Matlab®. A Figura 3 mostra o sEMG de uma das mulheres durante a execução de seu primeiro movimento cilíndrico e a Figura 4 mostra o resultado após a aplicação do




Figura 2: Ilustração dos movimentos realizados pelos voluntários.

filtro de variâncias no mesmo sinal.




Figura 3: sEMG original durante a execução do movimento cilíndrico.




Figura 4: Resultado após o filtro de variâncias.

Em seguida, o algoritmo segue para a extração de características como descrito no item 2.3.

Após todo o processo de filtragem e extração das características os dados foram divididos em dois testes.

- Primeiro teste: com o total de 30 repetições de cada movimento por pessoa foram utilizadas 20 amostras para treino e 10 amostras para validação.
- Segundo teste: neste caso, uma técnica de validação cruzada do tipo *holdout* foi testada, utilizando-se 70% dos dados para treino e 30% para validação, sendo realizadas 100 repetições e retirada a média de acerto das mesmas.

Com os testes já definidos é possível aplicar o classificador SVM para a classificação dos movimentos, como descrito no item 2.4. Para este projeto utilizou-se o algoritmo de treinamento C-SVC (*multi-class classification*) e o tipo de função *kernel* utilizado foi o linear. Testes com outros

Tabela 1: Matriz confusão apresentando os resultados para o primeiro teste.

		Classe Predita					
		M1	M2	M3	M4	M5	M6
Real	M1	94	2		4		
	M2	10	82	2	2	4	
	M3	16	2	66			16
	M4	20		10	56		14
	M5	4	4	8		84	
	M6			26	14		60

kernels foram realizados, no entanto, os melhores resultados foram encontrados com utilizando-se o kernel linear. Tais resultados demonstram que a seleção das 11 características já foram suficientes para a separação dos tipos de movimentos.

4 Testes e Resultados

Com o intuito de facilitar a leitura, os movimentos foram colocados em ordem alfabética pelos seus respectivos nomes em inglês, ou seja, Movimento 1 (*Cylindrical*), Movimento 2 (*Hook*) Movimento 3 (*Lateral*), Movimento 4 (*Palmar*), Movimento 5 (*Spherical*) e Movimento 6 (*textitTip*).

4.1 Primeiro Teste

Neste teste as repetições dos movimentos foram separadas e, para cada voluntário, tem-se uma matriz 120×11 (66,7%) para treino e uma matriz 60×11 (33,3%) para validação.

Os resultados serão apresentados na Tabela 1 através de matriz confusão, para facilitar a compreensão dos mesmos, além de uma avaliação geral apresentada na Tabela 2.

Para os resultados obtidos por movimento, mostrados na Tabela 1 é interessante destacar os movimentos 1 e 5, com 94% e 84% de acerto respectivamente. Além disso, os movimentos 3 e 4 apresentaram os piores resultados dentre os movimentos realizados. Isso pode ser explicado pela semelhança entre os movimentos, além do fato da força aplicada aos mesmos foi deixada para que os voluntários escolhessem livremente.

Tabela 2: Resultados obtidos fazendo uma avaliação geral por pessoa do primeiro teste.

Indivíduo	# de Acertos	% de Acertos
Mulher 1	44	73,33
Mulher 2	52	86,67
Mulher 3	43	71,67
Homem 1	43	71,67
Homem 2	30	65,00

Com os testes realizados também foi possível obter resultados satisfatórios por pessoas, como visto na Tabela 2. O resultado global do primeiro teste por pessoa nos dá um total de 221 movimentos acertados em 300 movimento testados, resultando em uma porcentagem de 73,67% de acertos.

4.2 Segundo Teste

Neste teste foi utilizada a validação cruzada do tipo *holdout* com 100 repetições. As dimensões da matriz de cada um dos voluntários utilizada para este teste foi de 126×11 (70%) para treinamento e 54×11 (30%) para validação.

Os resultados gerais serão apresentados por pessoa e são apresentados na Tabela 3.

Tabela 3: Resultados gerais obtidos segundo teste utilizando a técnica de validação cruzada do tipo *holdout*.

Indivíduo	% de Acertos	Margem de Erro
Mulher 1	74,87	1,42
Mulher 2	89,46	0,74
Mulher 3	84,81	1,06
Homem 1	76,13	1,09
Homem 2	86,93	0,68

Como os resultados obtidos anteriormente, os resultados aqui apresentados também foram satisfatórios, indicando que o classificador escolhido apresenta uma robustez em classificar os movimentos propostos, com destaque para a Mulher 2 com acerto de 89,46%. Neste contexto, o resultado global do segundo teste por pessoa nos dá uma porcentagem média de 82,44% de acertos.

5 Conclusões e Trabalhos Futuros

Diante dos resultados obtidos e realizando uma comparação com o artigo de (Sapsanis et al., 2013), ficou clara a eficiência do classificador, como mostrado na Tabela 4. Destaca-se, portanto, no trabalho proposto a eficiência e robustez das análises por pessoa e por movimento da metodologia implementada, utilizando técnicas bastante simples de filtragem, extração de características e do classificador SVM. No segundo teste, a técnica de validação cruzada, ao atingir altas taxas de acerto, se aproxima do trabalho dos autores supracitados, porém, utilizando-se menos dados com uma metodologia distinta.

Algumas melhorias podem ser sugeridas como trabalhos futuros com o objetivo de alcançar melhores resultados. Dentre as opções pode-se citar:

- Analisar as características também no domínio da frequência, como a Transformada Wavelet.
- Utilização de sensores EMG e eletrodos mais robustos e de maior confiabilidade, assim como o local em que os mesmos serão posicionados.
- Estabelecer padrões de força e velocidade de execução dos movimentos.
- Utilização de outros classificadores para averiguar a melhoria dos resultados, classificadores como PLS (*Partial Least Squares*), k-NN

Tabela 4: Comparação dos resultados encontrados com o trabalho desenvolvido por (Sapsanis et al., 2013).

	(Sapsanis et al., 2013)	Projeto Realizado	
Número de voluntários	6	5	
Amostras de Sinal por Movimento	Mais de 20.000	3.000	
Metodologia	PCA e Classificador Linear	Filtro de Variâncias, Extração de Características e Classificador SVM	Filtro de Variâncias, Extração de Características, Validação Cruzada e Classificador SVM
Resultados	87,70%	73,67%	82,44%

(*K-Nearest Neighbors*) e *Deep Learning Neural Network*.

Referências

- Alkan, A. and Günay, M. (2012). Identification of emg signals using discriminant analysis and svm classifier, *Expert Systems with Applications* **39**(1): 44–47.
- Andrade, N. A. (2007). *Desenvolvimento de um sistema de aquisição e processamento de sinais eletromiográficos de superfície para a utilização no controle de próteses motoras ativas*, Master's thesis, Universidade de Brasília.
- Cavalieri, D. C. (2007). *Interface homem-máquina para uma cadeira de rodas baseada no movimento ocular e piscadas de olhos*, Master's thesis, Universidade Federal do Espírito Santo.
- da Silveira Araújo, D. R. S., Botelho, T., Rodrigues, C., Frizera, A., Ferreira, A. and Rocon, E. (2014). Plataforma multimodal para controle de dispositivos de reabilitação de membros inferiores, *XXIV Congresso Brasileiro de Engenharia Biomédica - CBEB 2014*.
- Fleury-Rosa, S. S. R. (2005). Estudo e desenvolvimento de uma prótese robótica de perna comandada por sinais eletromiográficos, *IV Congresso Iberdiscap (Red Iberoamericana de Tecnologías de Apoyo a la Discapacidad)*.
- Gonçalves, R. S. and Carvalho, J. C. M. (2010). Desenvolvimento de uma estrutura robótica paralela atuada por cabos para reabilitação dos movimentos do ombro., *Congresso Nacional de Engenharia Mecânica*.
- Kaur, G., Arora, A. S. and Jain, V. K. (2009). Multi-class support vector machine classifier in emg diagnosis, *Transactions on Signal Processing* **5**(12): 379–389.
- Khan, M. T. and Hasan, M. T. (2015). Comparison between knn and svm for emg signal classification, *International Journal on*
- Recent and Innovation Trends in Computing and Communication* **3**(12): 6799–6801.
- Kirchner, E. A., Tabie, M. and Seeland, A. (2014). Multimodal movement prediction - towards an individual assistance of patients, *PLoS ONE* **9**(1): 1–9.
- Neto, A. F., Celeste, W. C., Martins, V. R., Filho, T. F. B. and Filho, M. S. (2006). Human-machine interface based on electro-biological signals for mobile vehicles, *2006 IEEE International Symposium on Industrial Electronics*, Vol. 4, pp. 2954–2959.
- Ortolan, R. L., Cura, V. O. D., Ferreira, F. A., Aguiar, M. L., Cunha, F. L. and Jr, A. C. (2000). Proposta de um sistema de controle de uma prótese mioelétrica multifunção para membros superiores, *Congresso Iberoamericano Iberdiscap*.
- Phinyomark, A., Limsakul, C. and Phukpattaranont, P. (2009). A novel feature extraction for robust emg pattern recognition, *Journal of Computing* **1**(1): 71–80.
- Rangayyan, R. M. (2015). *Biomedical signal analysis: a case-study approach*, IEEE Press series on biomedical engineering, 2nd edn, IEEE Press New York, Piscataway, New Jersey.
- Sapsanis, C., Georgoulas, G., Tzes, A. and Lymberopoulos, D. (2013). Improving emg based classification of basic hand movements using emd, *35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society 13 (EMBC 13)*, pp. 5754 – 5757.
- Souza, F. C. M. (2011). *Técnicas de buscas heurísticas para otimização de parâmetros de máquinas de vetores suportes*, Master's thesis, Universidade Federal de Pernambuco.
- Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*, Springer-Verlag New York, Inc., New York, NY, USA.