

RECONHECIMENTO DE PADRÕES MIOELETRICOS DO MOVIMENTO DOS DEDOS DA MÃO UTILIZANDO REDES NEURAIAS ARTIFICIAIS

Recognition of Myoelectric Patterns of Finger Motion Using Artificial Neural Network

Roberto Coelho de Almeida¹, Silvana Terezinha Faceroli²

Resumo: O objetivo deste trabalho é realizar o reconhecimento de padrões mioelétricos do movimento dos dedos da mão utilizando técnicas de processamento digital de sinais. Os sinais utilizados são provenientes de um banco de dados contendo seis classes de movimentos dos dedos da mão. Foram utilizadas ferramentas para extração de características do sinal mioelétrico no domínio do tempo e no domínio da frequência. No domínio do tempo foram calculados a raiz quadrada média, o valor retificado médio e o valor máximo absoluto do sinal. No domínio da frequência, foi aplicada ao sinal a Transformada de Fourier, calculando-se o espectro de densidade de potência e, posteriormente, a variável espectral frequência média. Com as características extraídas foi realizada a classificação dos movimentos dos dedos da mão, utilizando redes neurais artificiais. Com os resultados obtidos verificou-se que a rede neural *perceptrons de múltiplas camadas* (MLP) é uma técnica promissora em classificação de sinais mioelétricos alcançando no total 84,4% de acerto.

Palavras-chave: Eletromiografia, processamento digital de sinais, perceptrons de múltiplas camadas.

Abstract: *The goal of this paper is to make the recognition of myoelectric patterns of motion of the fingers using digital signal processing techniques. The signals used came from EMG database repository with signals related to six motions of the fingers. The tools used to extract features of the electromyography signals were in time domain and frequency domain. The root mean square (RMS), the average rectified value (ARV) and the maximum absolute value of the signals were calculated in the time domain. In the frequency domain, the Fourier Transform was applied to the signals, computing the power spectral density and afterwards the mean frequency of the signals. With features extracted was performed the classification of motion of the fingers, using multilayer perceptron neural network (MLP). The obtained results showed*

¹Graduação em Engenharia Mecatrônica, PIBICTI/IF Sudeste MG, robertcoal@hotmail.com

²Laboratório de Processamento de Sinais Aplicados, Núcleo de Informática, silvana.faceroli@ifsudestemg.edu.br

that the MLP neural network is a promising technique in myoelectric signals classification achieving in total 84,4% accuracy.

Keywords: *Electromyography, digital signal processing, multilayer perceptrons.*

INTRODUÇÃO

Portadores de deficiência física apresentam grandes problemas de integração na sociedade em função da dificuldade de executar tarefas simples no dia-a-dia. Com o desenvolvimento tecnológico na área de reabilitação humana este quadro está mudando gradativamente. De acordo com FAVIEIRO (2009), pesquisas científicas estão proporcionando o desenvolvimento de diversos mecanismos que visam melhorar a qualidade de vida dos portadores de necessidades especiais, ressaltando a vantagem do uso de sinais musculares (sinais mioelétricos) para movimento de próteses, com objetivo de torna-los mais independentes e com maiores chances de integração social.

Segundo FERREIRA ET AL. (2010), a eletromiografia de superfície compreende o exame dos potenciais elétricos dos músculos e possui destaque entre os métodos não invasivos para avaliação da atividade da musculatura esquelética. Diferentes músculos do antebraço são responsáveis pelos movimentos da mão e sinais eletromiográficos (sinal EMG) podem ser medidos nestes músculos mesmo após amputação da mão através de eletrodos, de acordo com MATTIOLI ET AL. (2010). Com a análise e processamento do sinal EMG é possível classificar e associar os movimentos com os sinais correspondentes, tornando-se essa uma importante interface homem-máquina em aplicações como controle de próteses e controle de mãos robóticas.

Devido às características estocásticas do sinal EMG são necessárias técnicas para extração de características do sinal para posterior análise. O processamento de sinais, que consiste em um grupo de técnicas matemáticas que podem ser aplicadas para extrair informações de sinais, segundo FERREIRA ET AL. (2010), é uma importante ferramenta para extração de informações do sinal EMG.

Assim, o objetivo deste trabalho é realizar o reconhecimento de padrões mioelétricos do movimento dos dedos da mão utilizando técnicas de processamento digital de sinais para, a partir das características extraídas, utilizar redes neurais artificiais para identificar tais movimentos. A topologia da rede neural artificial (RNA) utilizada foi a rede MLP.

MATERIAL E MÉTODOS

Os dados utilizados para classificação são provenientes de um repositório com sinais mioelétricos resultantes de uma pesquisa segundo KHUSHABA ET AL. (2012), onde oito voluntários com idades entre 20 e 35 anos, saudáveis, ativos, sem antecedentes de lesão do aparelho locomotor foram recrutados para executar o movimento dos dedos. Eles ficaram sentados em poltrona, com o braço dominante apoiado e fixado em uma posição para evitar variações do sinal EMG gerado.

Os dados EMG foram coletados por meio de dois canais (*Delsys DE 2.x series EMG sensors*) e processados pelo sistema *Bagnoli Desktop EMG*. Os sinais foram amplificados usando um amplificador *Delsys Bagnoli-8* com um ganho total de 1.000. Um conversor *Analogico – Digital* de 12 bits (*National Instruments, BNC-2090*) foi utilizado para amostrar o sinal a 4000 Hz e os dados do sinal foram adquiridos utilizando o *Delsys EMG Works Acquisition software* KHUSHABA ET AL. (2012).

Os sinais EMG foram coletados por meio de dois eletrodos de superfície auto-adesivo, onde um eletrodo captou sinais provenientes dos músculos *flexor superficial dos dedos e palmar longo* e o outro sinais provenientes dos músculos *extensor ulnar do carpo e extensor do 5º dedo*. O eletrodo de referência foi colocado no pulso dos voluntários. A Figura 1 demonstra a posição dos eletrodos.

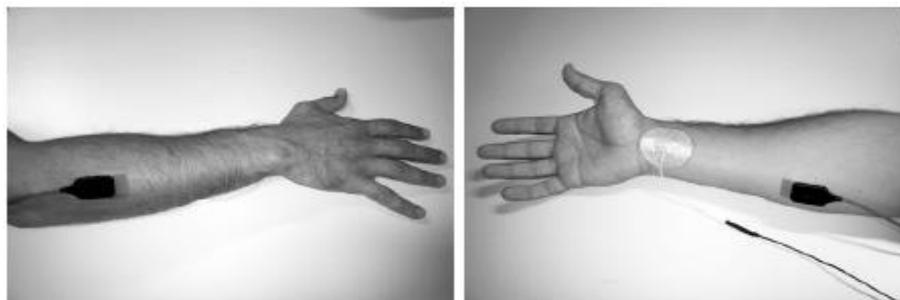


Figura 1 - Posição dos eletrodos.
Fonte: Adptado de KHUSHABA ET AL. (2012).

Foram realizadas dez classes de movimentos dos dedos, individuais e combinadas, de acordo com KHUSHABA ET AL. (2012). São elas: flexão individual de polegar (*thumb*), flexão individual de indicador (*index*), flexão individual de médio (*middle*), flexão individual de anular (*ring*), flexão individual de mínimo (*little*), fechamento combinado do polegar com cada um dos dedos e fechamento da mão (*hand close*). Os voluntários foram instruídos por um sinal sonoro para realizar uma contração e segurar a postura do dedo por um período de

cinco segundos e cada movimento foi repetido seis vezes por voluntário, com um período de repouso de três a cinco segundos entre os ensaios.

Neste trabalho, foram utilizados somente os dados referentes aos movimentos da flexão individual de cada dedo e o fechamento da mão, resultando em seis classes para classificação. Em cada classe foram feitas seis repetições para cada um dos oito voluntários, gerando um banco de dados com 288 movimentos. Os dados são disponibilizados pelo repositório sem pré-processamento, segundo KHUSHABA ET AL. (2012). Os movimentos utilizados são mostrados na Figura 2.



Figura 2 - Movimentos utilizados para classificação.
Fonte: Adaptado de KHUSHABA ET AL. (2012).

Segundo BARROS (2005), a análise do sinal mioelétrico é realizada através do processamento do sinal eletromiográfico, que é fundamental para o apoio ao diagnóstico de diversas patologias e também para o controle de próteses artificiais. E a partir do sinal EMG, se pode determinar o tipo de movimento que o usuário está executando. Em geral, o processamento de sinais EMG é composto pelas seguintes etapas: pré-processamento dos dados, extração de características e classificação.

A etapa de pré-processamento é aplicada ao sinal EMG adquirido devido ao sinal apresentar variações em suas características referentes ao circuito de aquisição do sinal, limitações nos amplificadores utilizados e interferência da rede elétrica na captação do sinal. Nesta etapa, geralmente, são aplicados filtros para utilizar o sinal somente na sua faixa de frequência útil e eliminar a interferência da rede elétrica.

De acordo com TELLO (2014) a etapa de extração de características consiste na transformação do sinal bruto em uma estrutura de informação relevante, chamado vetor característico, através da eliminação de ruído e destacando as informações importantes do sinal.

A classificação é a designação de objetos em classes predeterminadas, baseadas nas suas características. O projeto do classificador é independente da natureza do problema. Ao

contrário da escolha das características, que exige a compreensão dos fenômenos envolvidos, a concepção do classificador é feita com base em propriedades estatísticas das características e no critério de desempenho adotado. A classificação pode ser supervisionada ou não supervisionada. A classificação é dita supervisionada quando se conhece a classe que gerou cada padrão do conjunto de treino, assim o classificador é treinado a replicar a decisão correta para todos os padrões de treino. Na classificação não supervisionada, os padrões de treino não se encontram classificados, assim o algoritmo de treino tem de encontrar uma estrutura nos dados que permita dividi-los em classes. Com isso, como a informação disponível é menor, os resultados de classificação podem ser inferiores aos obtidos com a classificação supervisionada segundo MARQUES (2005).

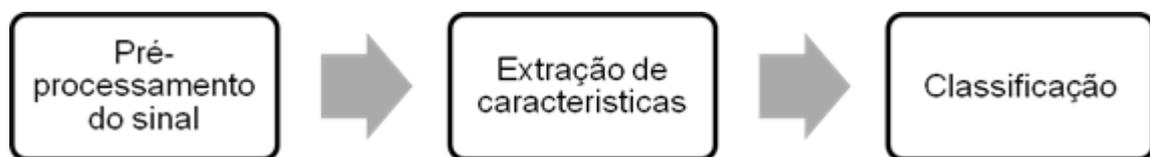


Figura 3 – Etapas do processamento do sinal EMG.

Na realização do trabalho, foi utilizado o software *MATLAB* para o pré-processamento, extração e classificação dos sinais. Na etapa de pré-processamento foram implementados um filtro *notch* de 50 Hz, para eliminar a interferência referente à rede elétrica e um filtro *passa-faixa* entre 20 Hz e 450 Hz, para utilizar o sinal na sua faixa de frequência da energia útil. Na implementação do filtro *notch* utilizou-se um filtro do tipo *IIR* (*infinite Impulse Response*) e para implementação do filtro *passa-faixa* foi utilizado um filtro de média móvel de ordem 400 do tipo *FIR* (*finite Impulse Response*). Os valores escolhidos para os filtros foram selecionados de acordo com o bom desempenho do filtro, de modo que o mesmo não apresentasse grande transitório no sinal de saída.

Na extração das características no domínio do tempo foi realizada a retificação de onda completa do sinal e calculados: o valor RMS, o valor ARV e o valor máximo absoluto do sinal. A retificação de onda completa converte os valores negativos em valores positivos e tem sido preferida na literatura por preservar a energia do sinal eletromiográfico, segundo FERREIRA ET AL. (2010). As equações de RMS e ARV são demonstradas na equação um e na equação dois, respectivamente:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$$

Equação 1 – Cálculo do valor RMS

Fonte: FERREIRA ET AL. (2010)

$$ARV = \frac{1}{N} \sum_{i=1}^N |x_i|$$

Equação 2 – Cálculo do valor ARV

Fonte: FERREIRA ET AL. (2010)

Os processamentos são aplicados para estimação da amplitude do sinal bruto eletromiográfico, uma vez que suas características estocásticas não permitem o cálculo analítico. Devido os histogramas de eletromiogramas experimentais ajustarem-se adequadamente às distribuições Gaussiana e Laplaciana, as variáveis RMS e ARV podem ser calculadas mesmo sem qualquer pré-processamento dos dados, de acordo com FERREIRA ET AL. (2010).

No domínio da frequência, foi aplicada ao sinal a Transformada de Fourier (TF), calculando-se o espectro de densidade de potência e, posteriormente, a variável espectral de frequência média (*Mean Frequency - MNF*). A densidade espectral de potencia de um processo estocástico é definida como a TF de sua função de autocorrelação no domínio do tempo discreto. A variável espectral MNF representa a média de todas as frequências do espectro de densidade de potência (PSD), segundo FERREIRA ET AL. (2010).

Como cada sinal foi coletado por dois canais e foram extraídas quatro características (RMS, ARV, valor máximo absoluto do sinal, MNF) de cada sinal, resultou-se em oito características no total. A Figura 4 demonstra a matriz de características realizada para classificação.

Matriz de Características

	1	2	3	288
Características	MAX ABS 1	MAX ABS 1	MAX ABS 1	MAX ABS 1
	MAX ABS 2	MAX ABS 2	MAX ABS 2	MAX ABS 2
	ARV 1	ARV 1	ARV 1	ARV 1
	ARV 2	ARV 2	ARV 2	ARV 2
	RMS 1	RMS 1	RMS 1	RMS 1
	RMS 2	RMS 2	RMS 2	RMS 2
	MNF PSD 1	MNF PSD 1	MNF PSD 1	MNF PSD 1
	MNF PSD 2	MNF PSD 2	MNF PSD 2	MNF PSD 2
	Movimentos				

Figura 4 – Matriz de Características

Na etapa de classificação, foi adotado o método supervisionado e foram utilizadas as redes neurais artificiais. A topologia da rede neural artificial (RNA) utilizada para implementar o reconhecimento dos movimentos foi a rede *perceptrons de múltiplas camadas*. A MLP consiste em um conjunto de unidades sensoriais que constitui a camada de entrada, uma ou mais camadas ocultas de nós computacionais e uma camada de saída, onde o sinal de entrada se propaga para frente através da rede, camada por camada, segundo FAVIEIRO (2009). O algoritmo de aprendizado utilizado na RNA foi o *backpropagation*, onde é aplicado um vetor de entrada pré-determinado na RNA e se analisa a resposta desejada para determinar o valor da função de erro. O sinal de erro é propagado para trás através da rede, contra a direção das conexões sinápticas. Os pesos sinápticos são ajustados de modo que a resposta real da rede se mova para mais perto da resposta desejada, em um sentido estatístico.

A rede neural foi implementada em MATLAB através da função *patternnet*, com três camadas. A primeira camada possui oito neurônios, cada um referente a uma característica de entrada (vetor coluna). A segunda camada possui 60 neurônios, valor que foi obtido iterativamente, de acordo com os resultados dos testes realizados. Apesar do número razoável de neurônios foram feitos testes com dados novos e a rede não apresentou *overfitting*. A camada de saída da rede possui seis neurônios referentes as seis classes de saída (vetor coluna).

A Figura 5 mostra os vetores de entrada e saída da rede neural MLP.

ENTRADA		SAÍDA						LEGENDA	
vetor coluna		vetor coluna							
MAX ABS 1		1	0	0	0	0	0	1 - MÃO FECHADA	
MAX ABS 2		0	1	0	0	0	0	2 - POLEGAR	
ARV 1		0	0	1	0	0	0	3 - INDICADOR	
ARV 2		0	0	0	1	0	0	4 - MÉDIO	
RMS 1		0	0	0	0	1	0	5 - ANULAR	
RMS 2		0	0	0	0	0	1	6 - MÍNIMO	
MNF 1									
MNF 2		1	2	3	4	5	6		

Figura 5 - Vetores de entrada e saída da rede neural MLP.

Na rede neural MLP, como função de ativação nas camadas, utilizou-se a função tangente hiperbólica (função do tipo sigmoide) que limita a saída do neurônio na faixa entre -1 e 1. No treinamento da RNA foi utilizado o algoritmo de treinamento *Levenberg-Marquardt* (LM), indicado como um método muito rápido para formação de redes neurais MLP de tamanho moderado, de acordo com FAVIEIRO (2009). As definições das condições de parada foram: 500 épocas de treinamento, erro médio quadrático menor que 10^{-7} e o gradiente igual a 10^{-10} .

Foram utilizados os dados da matriz de características para classificação dos movimentos. Os dados referentes a quatro repetições de cada movimento dos voluntários foram utilizados para treino, resultando em 192 amostras e os dados referentes a duas repetições de cada movimento dos voluntários foram utilizados para teste, resultando em 96 amostras. No algoritmo desenvolvido da rede neural, as 192 amostras de treino foram utilizadas para criação da rede, sendo estas divididas em 90% para treino, 5% para validação e 5% para teste de forma aleatória. As 96 amostras restantes foram utilizadas para o teste da RNA.

RESULTADOS

Os resultados são demonstrados através da matriz de confusão que relaciona a saída classificada com a saída desejada para o classificador utilizado. As células em verde, em diagonal, representam o número de amostras classificadas corretamente em cada classe. As células vermelhas demonstram o número de amostras classificadas em classes erradas. As células em cinza mostram o percentual de acerto (verde) e de erro (vermelho) de cada classe, com as células em cinza da vertical relacionando o acerto da classe para todas as amostras classificadas na classe e com as células em cinza da horizontal relacionando o acerto da classe

com o total de amostras da classe. O percentual total de acertos (verde) e de erros (vermelho) é mostrado na célula em azul.

A Figura 6 demonstra o treinamento da rede e o critério de parada que foi atingido, sendo o gradiente igual a 10^{-10} .

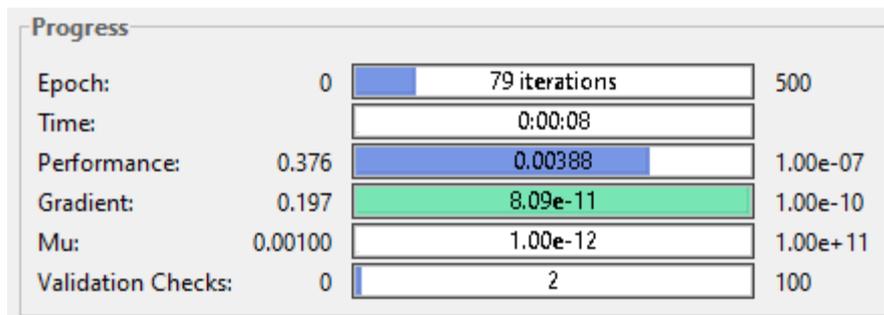


Figura 6 – Critério de parada da RNA.

Fonte: *MATLAB*

O resultado da rede neural para as 192 amostras de treino apresentou o total de 98,4% de acerto. No treino, o resultado para as classes de movimento foram de: 96,9% para *mão fechada*, 100% para *polegar*, 100% para *indicador*, 93,8% para *médio*, 100% para *anular* e 100% para *mínimo*.

AMOSTRAS DE TREINO - REDE NEURAL MLP

SAÍDA CLASSIFICADA	1	2	3	4	5	6	Total
1	31 16.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	1 0.5%	32 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	97.0% 3.0%
3	0 0.0%	0 0.0%	32 16.7%	1 0.5%	0 0.0%	0 0.0%	97.0% 3.0%
4	0 0.0%	0 0.0%	0 0.0%	30 15.6%	0 0.0%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	32 16.7%	0 0.0%	100% 0.0%
6	0 0.0%	0 0.0%	0 0.0%	1 0.5%	0 0.0%	32 16.7%	97.0% 3.0%
	96.9% 3.1%	100% 0.0%	100% 0.0%	93.8% 6.3%	100% 0.0%	100% 0.0%	98.4% 1.6%
	1	2	3	4	5	6	

SAÍDA DESEJADA

Figura 7 – Resultado das amostras de treino.

Fonte: *MATLAB*

Com as 96 amostras restantes, a rede neural foi testada, obtendo o resultado total de 84,4% de acerto. O resultado para as classes de movimento no teste da rede MLP foram de: 93,8% para *mão fechada*, 81,3% para *polegar*, 81,3% para *indicador*, 75% para *médio*, 100% para *anular* e 75% para *mínimo*. A Figura 8 demonstra o resultado para o teste da rede neural criada.

AMOSTRAS DE TESTE - REDE NEURAL MLP

SAÍDA CLASSIFICADA	1	15 15.6%	0 0.0%	0 0.0%	1 1.0%	0 0.0%	0 0.0%	93.8% 6.3%
	2	0 0.0%	13 13.5%	1 1.0%	0 0.0%	0 0.0%	0 0.0%	92.9% 7.1%
	3	0 0.0%	2 2.1%	13 13.5%	3 3.1%	0 0.0%	4 4.2%	59.1% 40.9%
	4	1 1.0%	1 1.0%	1 1.0%	12 12.5%	0 0.0%	0 0.0%	80.0% 20.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	16 16.7%	0 0.0%	100% 0.0%
	6	0 0.0%	0 0.0%	1 1.0%	0 0.0%	0 0.0%	12 12.5%	92.3% 7.7%
			93.8% 6.3%	81.3% 18.8%	81.3% 18.8%	75.0% 25.0%	100% 0.0%	75.0% 25.0%
		SAÍDA DESEJADA						

Figura 8 – Resultado do teste da rede neural MLP.

Fonte: *MATLAB*

DISCUSSÃO

Com os resultados obtidos observa-se que a rede neural MLP apresentou um resultado satisfatório na classificação dos movimentos dos dedos da mão através das características extraídas dos sinais mioelétricos. Com os testes realizados observamos que variando o erro médio quadrático, variamos os ciclos de treinamento pois para o valor alto do erro médio quadrático temos poucos ciclos de treinamento visto que o critério de parada é atingido rapidamente. O inverso ocorre para número muito baixo do erro médio quadrático. Assim, esse valor deve ser ajustado visando o treinamento moderado da rede em relação ao valor adequado para o erro médio quadrático. Observamos também que o gradiente é um indicativo da taxa de aprendizado da rede, quando ele é muito baixo, indica que não ocorrerão mudanças significativas no aprendizado. Assim, na configuração da rede neural, destaca-se o ajuste dos parâmetros da rede de acordo com o conjunto de dados e o objetivo da classificação como

ponto de melhoria no desempenho da RNA.

Analisando o teste da rede neural com as 96 amostras, observamos que o menor percentual de acerto foi de 75% para as classes de Flexão do *médio* e Flexão do *mínimo* e o maior valor foi de 100% para a Flexão do *anular* resultando na diferença de 25% nesses resultados. A essa diferença podemos atribuir o fato do sinal eletromiográfico apresentar diferenças de pessoa para pessoa já que é definido como uma manifestação de uma ativação neuromuscular associada a uma contração muscular sendo este sinal extremamente complexo e afetado pelas propriedades anatômicas e fisiológicas dos músculos.

Entre as vantagens do uso da rede neural, segundo VALE (2009), cita-se tolerância a dados ruidosos, habilidade de representar qualquer função, seja ela linear ou não, e capacidade de lidar com padrões de entrada representados por vetores de alta dimensão.

CONCLUSÃO

Através das características extraídas de sinais mioelétricos, referentes aos movimentos dos dedos das mãos, foi aplicado o método das redes neurais artificiais para classificação desses sinais de acordo com os movimentos realizados. De acordo com os resultados obtidos, verificou-se que a rede neural MLP apresentou desempenho satisfatório mostrando-se uma técnica promissora em classificação de sinais mioelétricos.

Com relação a ALMEIDA ET AL. (2014) destaca-se avanços na configuração da rede neural, com redução significativa do número de neurônios na camada escondida mantendo desempenho similar nos testes realizados.

Em trabalhos futuros, pretende-se aumentar o banco de dados e aperfeiçoar a rede neural para obtenção de melhores resultados.

Agradecimentos

Agradeço ao Instituto Federal do Sudeste de Minas Gerais por me proporcionar a realização deste trabalho.

BIBLIOGRAFIA

ALMEIDA RC, FACEROLI ST. Análise comparativa das técnicas KNN e rede neural MLP na classificação de padrões mioelétricos. In XXIV Congresso Brasileiro de Engenharia Biomédica. 2014, Uberlândia. Anais do **XXIV Congresso Brasileiro de Engenharia Biomédica**. 2014, Uberlândia

BARROS KR. **Metodologia para Classificação de sinais EMG para controle de próteses com baixo esforço computacional**. 2005, 90. Dissertação (Mestrado – Pós Graduação em Engenharia Eletrica), Universidade Federal de Uberlândia, Uberlândia, 2005.

FAVIEIRO GW. **Controle de uma prótese experimental do segmento mão braço por sinais mioeletricos e redes neurais artificiais**. 2009, 111. Trabalho de Conclusão de Curso (Graduação em Engenharia de Computação), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009.

FERREIRA AS; GUIMARÃES FS; SILVA JG. Aspectos metodológicos da eletromiografia de superfície: considerações sobre os sinais e processamentos para estudo da função neuromuscular. **Revista Brasileira de Ciências do Esporte**, 31: 11-30, 2010.

KHUSHABA RN, TAKRURI M, KODAGODA S, DISSANAYAKE G. Toward Improved Control of Prosthetic Fingers Using Surface Electromyogram (EMG) Signals. **Expert Systems with Applications**, 39 (12): 10731–38, 2012.

MARQUES JS. **Reconhecimento de padrões: métodos estatísticos e neurais**. 2ª Edição. Lisboa: IST Press, 2005.

MATTIOLI F, CAETANO DSD, GOMES W, LAMOUNIER E, CARDOSO A. Utilização de redes neurais para a classificação de sinais EMG aplicados no controle de próteses virtuais de mão. In: VII Workshop de Realidade Virtual e Aumentada 2010, São Paulo, Brasil. **Anais do VII Workshop de Realidade Virtual e Aumentada**. 2010, São Paulo.

TELLO RJMG. **Extração de características e classificação de sinais sEMG aplicados a uma prótese de mão virtual**. [dissertação]. Vitória: Universidade Federal do Espírito Santo, 2013.

VALE KMO. **Uma análise de métodos de distribuição de atributos em comitês de classificadores**. 2009, 135. Dissertação (Mestrado – Programa de Pós Graduação em Sistemas de Computação), Universidade Federal do Rio Grande do Norte, Natal, 2009.