

# ANÁLISE COMPARATIVA DAS TÉCNICAS KNN E REDE NEURAL MLP NA CLASSIFICAÇÃO DE PADRÕES MIOELÉTRICOS

R. C. Almeida, S. T. Faceroli

Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas Gerais - Campus Juiz de Fora, Juiz de Fora, Brasil  
e-mail: robertcoal@hotmail.com

**Resumo:** O objetivo deste trabalho é apresentar uma análise comparativa entre diferentes técnicas utilizadas para classificação dos movimentos dos dedos das mãos utilizando sinais mioelétricos. Foram utilizadas ferramentas para extração de características do sinal mioelétrico no domínio do tempo e no domínio da frequência. No domínio do tempo, foi realizada a retificação de onda completa do sinal e calculados a raiz quadrada média (*Root Mean Square - RMS*), o valor retificado médio (*Average Rectified Value - ARV*) 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 (*Mean Frequency - MNF*). Para análise comparativa das técnicas de classificação, utilizou-se o método dos *k*-vizinhos mais próximos (*k-nn*) e a rede neural *perceptrons de múltiplas camadas* (MLP). O método dos *k*-vizinhos mais próximos apresentou 64,6% de acerto no total e a rede neural MLP obteve 85,4% de acerto.

**Palavras-chave:** Eletromiografia, redes neurais artificiais, método dos *k*-vizinhos mais próximos.

**Abstract:** *The goal of this paper is to show a comparative analysis between different techniques used to classify the motion of the fingers using surface electromyography signals (EMG). The tools used to extract features of the electromyography signals were in time domain and frequency domain. The full wave rectification was computed and 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 (PSD) and afterwards the mean frequency (MNF) of the signals. In order to compare analytically the classification techniques, the methods used were: k-nearest neighbors method (k-nn) and Multilayer Perceptron neural network (MLP). The k-nn method obtained 64,6% classification accuracy and the MLP achieved 85,4% classification accuracy.*

**Keywords:** *Electromyography, artificial neural network, k-nearest neighbors method.*

## Introdução

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 [1]. Diferentes músculos do antebraço são responsáveis pelos movimentos da mão e sinais eletromiográficos (EMG) podem ser medidos nestes músculos mesmo após amputação da mão através de eletrodos [2]. 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 [1], é uma importante ferramenta para extração de informações do sinal EMG.

Neste trabalho, foram utilizadas as técnicas do método dos *k*-vizinhos mais próximos (*k-nn*) e da rede neural *perceptrons de múltiplas camadas* (MLP) para realizar a classificação do movimento dos dedos da mão através das características extraídas do sinal eletromiográfico. Com os resultados obtidos, foi realizada a análise comparativa entre os métodos aplicados e o respectivo desempenho alcançado.

## Materiais e métodos

**Banco de dados-** Os dados utilizados para classificação são provenientes de um repositório com sinais mioelétricos resultantes de uma pesquisa [3] 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 A/D 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* [3].

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 [3].

Foram realizadas dez classes de movimentos dos dedos, individuais e combinadas [3]. 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 [3]. Os movimentos utilizados são mostrados na Figura 1.



Figura 1 - Movimentos utilizados para classificação.

**Pré-processamento dos sinais-** Na realização deste 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 e um filtro *passa-faixa* entre 20 Hz e 450 Hz. 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*).

**Extração de características-** Na extração das características no domínio do tempo foi realizada a retificação de onda completa do sinal e calculados: a raiz quadrada média (*Root Mean Square - RMS*), o valor retificado médio (*Average Rectified Value - 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 [1]. As equações de RMS e ARV são demonstradas nas equações (1) e (2), respectivamente:

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

$$ARV = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (2)$$

Os processamentos são aplicados para estimação da amplitude do sinal bruto eletromiográfico, uma vez que suas características estocásticas não permitem o cálculo analítico e 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 [1].

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 de frequência média (*Mean Frequency - MNF*). O espectro de densidade de potência é definido como a Transformada de Fourier (TF) da função AC do sinal temporal. A variável espectral MNF representa a média de todas as frequências do espectro de densidade de potência (PSD) [1].

Como cada sinal foi coletado por dois canais [3] e foram extraídas quatro características (RMS, ARV, valor máximo absoluto do sinal, MNF) de cada sinal, resultou-se em 8 características no total. Desta forma, a dimensão da matriz de dados é de 8 linhas por 288 colunas.

**Técnicas de classificação-** Na análise comparativa das técnicas de classificação, realizou-se a comparação entre o método dos *k-vizinhos* mais próximos (*k-nn*) e a rede neural *perceptrons de múltiplas camadas* (MLP).

O método *k-nn* é um dos mais simples e mais utilizados algoritmos de aprendizado, e consiste em classificar um novo exemplo calculando a distância entre os *K* exemplos mais próximos a ele. Em [4] temos a seguinte definição: dado um conjunto *X* de valores de treinamento, cada elemento de *X* é um vetor  $(x_1, x_2, \dots, x_n; C)$ , onde *C* é a classe a qual esse vetor pertence. Cada vetor pode ser visto como um ponto num espaço *n*-dimensional. Sendo *Y* igual a um novo vetor  $(y_1, \dots, y_n)$ , ainda não classificado, para classificá-lo, calculam-se as distâncias a todos os vetores de treinamento e consideram-se os *K* vetores de treinamento mais próximos de *Y*. Assim, dentre esses *K* vetores, *Y* é classificado dentro da classe *C* que aparece com maior frequência. Na realização do trabalho, o algoritmo foi implementado em *MATLAB* através da função *knnclassify*, sendo os vetores formados por vetores coluna da matriz de características.

A topologia da rede neural artificial (RNA) utilizada para implementar o reconhecimento dos movimentos foi a rede *perceptrons de múltiplas camadas* (MLP). 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 [5]. O algoritmo de aprendizado utilizado na rede implementada 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 8 neurônios, cada um referente a uma característica de entrada (vetor coluna). A segunda camada possui 240 neurônios, valor que foi obtido iterativamente, de acordo com os resultados dos testes realizados. Apesar do elevado número de neurônios na camada escondida, foram feitos testes com dados novos e a rede não apresentou *overfitting*. A camada de saída da rede possui 6 neurônios referentes as seis classes de saída (vetor coluna). A Figura 2 demonstra a rede criada no *MATLAB*.




Figura 2 - Rede neural MLP criada no *MATLAB*.

A Figura 3 mostra os vetores de entrada e saída da rede neural MLP.

ENTRADA vetor coluna	SAÍDA vetor coluna	LEGENDA
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 3 - 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 [5]. As definições das condições de parada foram: 500 épocas de treinamento, erro médio quadrático menor que  $10^{-7}$  e o gradiente igual a  $10^{-10}$ .

No método *k-nn* e na rede neural, utilizaram-se os dados da matriz de características, citada anteriormente,

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 implementado 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. As 96 amostras restantes foram utilizadas para o teste da rede neural criada.

## Resultados

No método *k-nn* foram realizados diferentes experimentos, alterando-se o número de vizinhos próximos e a especificação da distância utilizada. A maior porcentagem de acertos foi alcançada utilizando 10 vizinhos próximos e calculando a distância euclidiana. A matriz de confusão para as amostras de teste é demonstrada na Figura 4. A matriz de confusão 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. Analisando a matriz de confusão para as amostras de teste do classificador *k-nn*, observamos que a porcentagem total de acertos foi de 64,6% e o acerto para cada classe de movimento foi de: 81,3% para *mão fechada*, 43,8% para *polegar*, 56,3% para *indicador*, 62,5% para *médio*, 87,5% para *anular* e 56,3% para *mínimo*.

AMOSTRAS DE TESTE - MÉTODO K-NN							
SAÍDA CLASSIFICADA	1	2	3	4	5	6	
1	13 13.5%	4 4.2%	1 1.0%	0 0.0%	0 0.0%	0 0.0%	72.2% 27.8%
2	0 0.0%	7 7.3%	2 2.1%	0 0.0%	0 0.0%	1 1.0%	70.0% 30.0%
3	0 0.0%	2 2.1%	9 9.4%	2 2.1%	2 2.1%	4 4.2%	47.4% 52.6%
4	0 0.0%	2 2.1%	0 0.0%	10 10.4%	0 0.0%	0 0.0%	83.3% 16.7%
5	2 2.1%	0 0.0%	2 2.1%	3 3.1%	14 14.6%	2 2.1%	80.9% 39.1%
6	1 1.0%	1 1.0%	2 2.1%	1 1.0%	0 0.0%	9 9.4%	64.3% 35.7%
	81.3% 18.8%	43.8% 56.3%	56.3% 43.8%	62.5% 37.5%	87.5% 12.5%	56.3% 43.8%	64.6% 35.4%
	1	2	3	4	5	6	
	SAÍDA DESEJADA						

Figura 4 - Matriz de confusão para o método *k-nn*.

O resultado da rede neural foi mais satisfatório, obtendo-se para as 192 amostras de treino o resultado total de 97,9% de acerto. Com as 96 amostras restantes foi realizado o teste da rede neural criada e analisando a matriz de confusão da Figura 5, observou-se o resultado total de 85,4% de acerto, sendo o resultado para as classes de movimento de: 100,0% para *mão fechada*, 87,5% para *polegar*, 81,3% para *indicador*, 81,3% para *médio*, 93,8% para *anular* e 68,8% para *mínimo*, comprovando a não ocorrência do *overfitting*.

SAÍDA CLASSIFICADA	1	2	3	4	5	6	
1	16 16.7%	0 0.0%	0 0.0%	2 2.1%	0 0.0%	0 0.0%	88.9% 11.1%
2	0 0.0%	14 14.6%	1 1.0%	0 0.0%	0 0.0%	0 0.0%	93.3% 6.7%
3	0 0.0%	1 1.0%	13 13.5%	0 0.0%	0 0.0%	5 5.2%	68.4% 31.6%
4	0 0.0%	1 1.0%	1 1.0%	13 13.5%	0 0.0%	0 0.0%	86.7% 13.3%
5	0 0.0%	0 0.0%	0 0.0%	1 1.0%	15 15.6%	0 0.0%	93.8% 6.3%
6	0 0.0%	0 0.0%	1 1.0%	0 0.0%	1 1.0%	11 11.5%	84.6% 15.4%
	100% 0.0%	87.5% 12.5%	81.3% 18.8%	81.3% 18.8%	93.8% 6.3%	68.8% 31.3%	85.4% 14.6%
	1	2	3	4	5	6	
	SAÍDA DESEJADA						

Figura 5 - Matriz de confusão para rede neural MLP.

## Discussão

Com os resultados obtidos, percebe-se que o método *k-nn* é um algoritmo de fácil implementação porém com grande complexidade computacional, uma vez que para cada exemplo são calculadas as distâncias a todos os demais. Além disso, é bastante sensível a ruídos [4] e apesar do pré-processamento do sinal, ainda podem conter ruídos no sinal EMG analisado. Com isso observa-se o menor desempenho deste método que obteve 64,6% de acerto.

Na implementação da rede neural, observamos que com o ajuste dos parâmetros podemos melhorar o desempenho da rede. Entre as vantagens do uso da rede neural 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 [4]. Assim observa-se que, com a implementação da rede neural, obtemos um desempenho melhor do que no método *k-nn*, alcançando no total 85,4% de acerto.

## Conclusão

A partir de características extraídas de sinais mioelétricos, referentes a movimentos dos dedos das mãos, foi aplicado o método *k-nn* e redes neurais artificiais para classificação desses sinais. De acordo

com os resultados obtidos, verificou-se que a rede neural MLP apresentou melhor desempenho mostrando-se uma técnica promissora em classificação de sinais mioelétricos. 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.

## Referências

- [1] 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 2010, 31: 11-30.
- [2] 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. VII Workshop de Realidade Virtual e Aumentada 2010, São Paulo, Brasil.
- [3] Khushaba RN, Takruri M, Kodagoda S, Dissanayake G. Toward Improved Control of Prosthetic Fingers Using Surface Electromyogram (EMG) Signals. Expert Systems with Applications 2012; 39 (12): 10731–38.
- [4] Vale KMO. Uma análise de métodos de distribuição de atributos em comitês de classificadores [dissertação]. Natal: Universidade Federal do Rio Grande do Norte; 2009.
- [5] Favieiro GW. Controle de uma prótese experimental do segmento mão braço por sinais mioelétricos e redes neurais artificiais [monografia]. Porto Alegre: Universidade Federal do Rio Grande do Sul, 2009.