



SEI-SICITE 2021

Pesquisa e Extensão para um mundo em transformação

XI Seminário de Extensão e Inovação  
XXVI Seminário de Iniciação Científica e Tecnológica  
08 a 12 de Novembro - Guarapuava/PR



# Aquisição e Classificação Contínua de Padrões em Sinais Mioelétricos Baseada em Wavelets e Redes Neurais Artificiais

## *Acquisition and Continuous Classification of Myoelectric Signal Patterns Based on Wavelets and Artificial Neural Networks*

Ayrton Correia Guedes \*, Paulo Rogério Scalassara †

Setembro de 2021

### RESUMO

Este estudo descreve o desenvolvimento de um sistema de aquisição e classificação de sinais mioelétricos. Alguns resultados são apresentados para mostrar a identificação de padrões nesses sinais a partir de um sistema com: coleta dos sinais através de eletrodos de superfície para eletromiografia, condicionamento analógico de sinais com amplificador de instrumentação e filtro ativo, digitalização e processamento digital. Esse processamento é composto: primeiramente, por um janelamento temporal sobre o instante em que identifica-se o sinal de contração muscular, sucessivamente, por uma decomposição desse sinal janelado por Transformada *Wavelet* e, enfim, pela classificação dos coeficientes em uma Rede Neural Artificial do tipo Perceptron Multicamadas. Além disso, são apresentadas comparações entre diferentes configurações no processamento digital, para entender quais parâmetros são mais significativos na classificação desses sinais. As comparações são sobre: o tamanho da janela temporal, o tipo e o nível de decomposição por Transformada *Wavelet*, e as quantidades de camadas escondidas e de neurônios na Rede Neural Artificial.

**Palavras-chave:** Sinais Eletromiográficos. *Wavelet*. Redes Neurais Artificiais. Perceptron Multicamadas. Classificador de padrões.

### ABSTRACT

This study describes the development of a myoelectric signal acquisition and classification system. Some results are presented to show the identification of patterns in these signals. The system contains: signal collection through surface electrodes for eletromyography, analog signal conditioning circuit with instrumentation amplifier and active filter, digitizing device and digital signal processing. This processing performs: first, the signal windowing at the moment the muscle contraction signal is identified, then the signal decomposition by Wavelet Transform and, at the end, the patterns classification of the coefficients in the Multilayer Perceptron Neural Network. In addition, is presented comparisons between different configurations in digital processing, in order to understand which parameters are most significant in classifying these signals. The comparisons are about: the size of the temporal window, the type and level of decomposition by the Wavelet Transform and the amount of hidden layers and neurons in the Artificial Neural Network.

**Keywords:** Electromyographic signals. *Wavelet*. Artificial Neural Network. Multilayer Perceptron. Patterns recognition.

\*  Engenharia Eletrônica, Universidade Tecnológica Federal do Paraná - UTFPR, câmpus Cornélio Procópio;  
 [ayrtonguedes@alunos.utfpr.edu.br](mailto:ayrtonguedes@alunos.utfpr.edu.br).

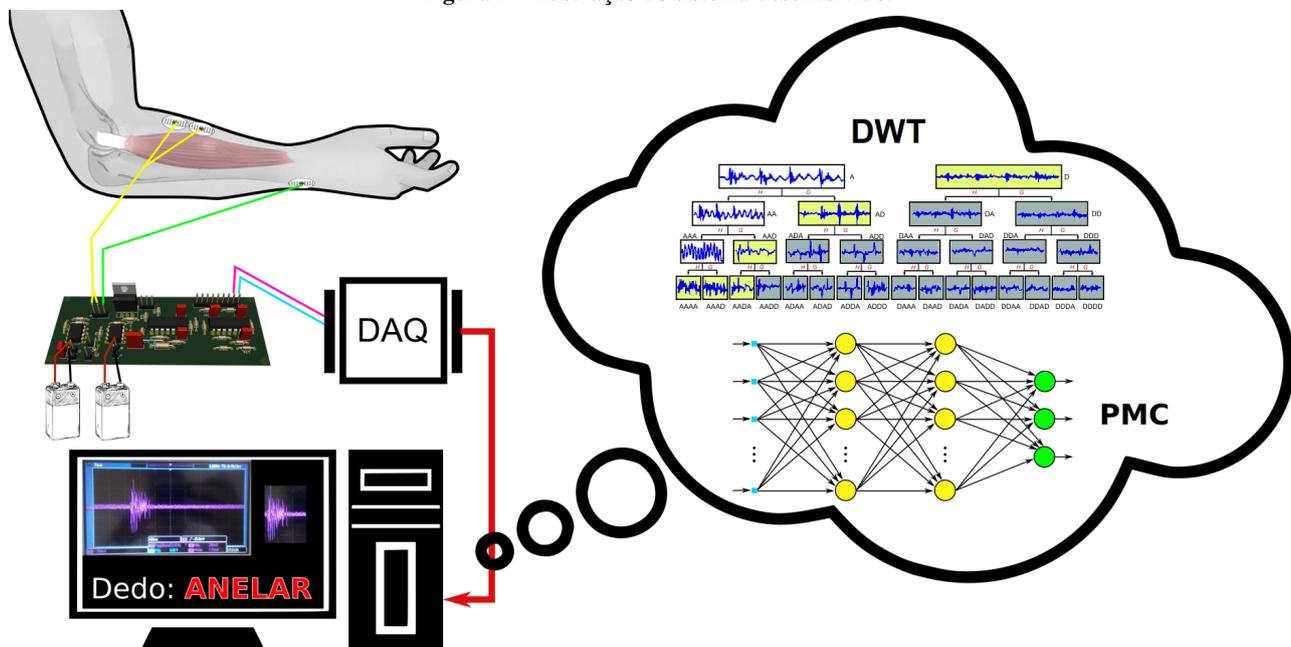
†  Departamento Acadêmico de Elétrica, Universidade Tecnológica Federal do Paraná - UTFPR, câmpus Cornélio Procópio;  
 [prscalassara@utfpr.edu.br](mailto:prscalassara@utfpr.edu.br).

## 1 INTRODUÇÃO

Sistemas mioelétricos ou eletromiográficos (EMG), coletados da superfície da pele, já são utilizados em muitas aplicações, incluindo diagnóstico clínico, próteses de assistência motora e em esquemas de estimulação elétrica funcional (PARKER, P. A.; SCOTT, 1986).

O objetivo desse estudo é testar um sistema de aquisição e classificação de padrões em sinais de EMG, após uma pesquisa na literatura sobre: os sinais mioelétricos, os circuitos eletrônicos para condicionamento de sinais e as técnicas de processamento digital para esse tipo de aplicação. O sistema que foi desenvolvido está ilustrado na Fig. 1. Esse sistema realiza a coleta dos sinais por meio de 3 eletrodos de superfície. Dois compõem o canal de entrada, e o terceiro pertence à referência para o circuito de condicionamento de sinais. O sinal é amplificado e filtrado por uma placa de circuito impresso (PCB), digitalizado por um dispositivo de aquisição de dados (DAQ) e classificado em um computador ou em um dispositivo para processamento digital de sinais (DSP).

Figura 1 – Ilustração do sistema desenvolvido.



Fonte: Autoria própria (2021).

Todos os sistemas de controle mioelétricos são baseados na suposição que os valores instantâneos dos sinais mioelétricos não contêm informação (HUDGINS; PARKER, P.; SCOTT, 1993). Assim que vários tecidos musculares se ativam, o conjunto se aproxima de um processo Gaussiano (PARKER, P. A.; STULLER; SCOTT, 1977). Segundo (HUDGINS; PARKER, P.; SCOTT, 1993), as componentes determinísticas dos sinais de EMG são de curta duração e ocorrem durante a fase inicial da contração.

Devido à natureza dos sinais mioelétricos, é razoável esperar uma larga variação nos valores das características entre indivíduos e entre posicionamentos dos eletrodos. Além disso, o padrão da forma de onda distingue-se para contrações que produzem diferentes movimentos do membro (HUDGINS; PARKER, P.; SCOTT, 1993).

A amplitude do sinal de EMG pode variar de 0 à 10  $mV_{pp}$  e a energia é limitada entre 0 Hz e 500 Hz, com a energia dominante ocorrendo entre 50 Hz e 150 Hz (ENDERLE; BRONZINO; BLANCHARD, 2005), (WEBSTER; NIMUNKAR, 2020).

Em (HUDGINS; PARKER, P.; SCOTT, 1993), utilizaram-se Redes Neurais Artificiais (RNA) do tipo



Perceptron multicamadas (PMC) para a classificação de sinais eletromiográficos. Obtiveram bons resultados e com treinamento rápido para uma rede de 8 neurônios na única camada escondida, treinada com o algoritmo *backpropagation*, alcançado taxas de acertos acima de 90 % para algumas classes de sinais. A camada escondida deve ser a menor possível para reduzir a complexidade do algoritmo, melhorar a generalização frente aos subconjuntos de teste e evitar a memorização excessiva, mas também suficiente para o correto mapeamento entrada/saída (DA SILVA; SPATTI; FLAUZINO, 2010) e (HUDGINS; PARKER, P.; SCOTT, 1993). A classificação dos padrões a partir do sinal amostrado bruto resultava em uma acurácia de classificação inaceitável. Uma maneira de reter algumas das informações estruturais, foi segmentar o transiente da forma de onda e determinar o conjunto de características baseado nas estatísticas para cada segmento. Algumas características calculadas foram: o valor absoluto médio, cruzamento por zero, *Slope Sign Changes*, entre outras.

Dentre as ferramentas para análise funcional, a Transformada *Wavelet* suscita grande interesse da comunidade de processamento digital de sinais por possuir a capacidade de representar sinais com resoluções variáveis no tempo e na frequência (DINIZ; SILVA; NETTO, 2014). A Transformada *Wavelet* surgiu como uma ferramenta para a análise de sinais não-estacionários, a sua versão discreta possui uma relação muito próxima com os bancos de filtros (VETTERLI; HERLEY, 1990).

Em (ENGLEHART; HUDGINS; PARKER, P. A., 2001), foram utilizadas as técnicas de: Transformada de Fourier de tempo curto (STFT), Transformada *Wavelet* Packets (WPT), Análise de Discriminantes Lineares (LDA) e Análise de Componentes Principais (PCA); para a extração dos conjuntos de características do sinais. E sucessivamente, foi usada a classificação por PMC para esses conjuntos de dados. As maiores acurácias foram alcançadas para a classificação com o conjunto de características extraídas por WPT/PCA, com 4 canais de entrada, para dados estacionários, obtendo-se uma taxa de acertos de 99.5 % na separação em 4 classes e 98 % na separação em 6 classes. Além disso, observou-se que 4 canais de entrada e dados estacionários permitiam uma acurácia maior que, respectivamente, 2 canais de entrada e dados transientes.

## 2 MÉTODO

A aquisição é composta pela fixação do eletrodos de superfície com os cabos devidamente isolados e pela placa com o circuito analógico de condicionamento dos sinais. Esse circuito, que realiza a amplificação e filtragem, é projetado a partir da amplitude e faixa de frequências esperadas para um sinal de EMG e pela faixa de tensão de operação do dispositivo de processamento digital. O objetivo é amplificar o sinal de EMG para cobrir ao máximo o fundo de escala do dispositivo de processamento do sinal.

O filtro é projetado a partir de uma especificação de: frequência de corte, *ripple* na faixa de passagem, frequência da banda de rejeição, faixa de rejeição e atenuação na banda de rejeição.

Para o circuito amplificador foi decidido utilizar um amplificador de instrumentação, que possui uma alta razão de rejeição de modo comum (CMRR) e permite ajustar o ganho de tensão de forma bastante simples com a escolha de duas resistências.

A partir das especificações e da escolha do tipo de filtro (Butterworth, Chebyshev, Elíptico, entre outros) obtêm-se a função de transferência do filtro. Foi decidido implementar um filtro passa-banda composto por: um passa-altas RC de primeira ordem, para retirada do *offset*, em cascata com um passa-baixas Chebyshev de quinta ordem, para retirada do ruído de frequências altas. O filtro Chebyshev foi realizado em um circuito de filtro ativo com amplificadores operacionais. O filtro apresentou uma banda de passagem entre 7 Hz e 1112 Hz.

Um dispositivo digitalizador dos sinais (DAQ) foi conectado entre a saída da placa de condicionamento dos

sinais e um computador. Então o processamento digital dos sinais foi realizado pelo computador dentro do software MATLAB.

O firmware desenvolvido detecta automaticamente o começo da contração pela variação da amplitude do sinal de EMG e salva uma quantidade de amostras a partir desse instante, com uma frequência de amostragem de 2 KHz. Esse sinal é decomposto até o 4 nível da Transformada *Wavelet* discreta (DWT), que fornece quatro coeficientes de detalhes e um coeficiente de aproximação (cD1, cD2, cD3, cD4 e cA4). A energia e a entropia de cada um desses coeficientes são calculadas. Os 10 valores que resultam desses cálculos são as entradas da PMC.

Em cada processo de treinamento e teste, a RNA foi treinada com um grupo de sinais e, sucessivamente, testada com outro grupo de sinais. Nenhum dos sinais do grupo de treinamento esteve presente no grupo de teste. O grupo de treinamento era composto por 100 sinais (20 sinais relacionados à contração individual de cada dedo) e o grupo de teste por 45 sinais (9 sinais relacionados à contração individual de cada dedo).

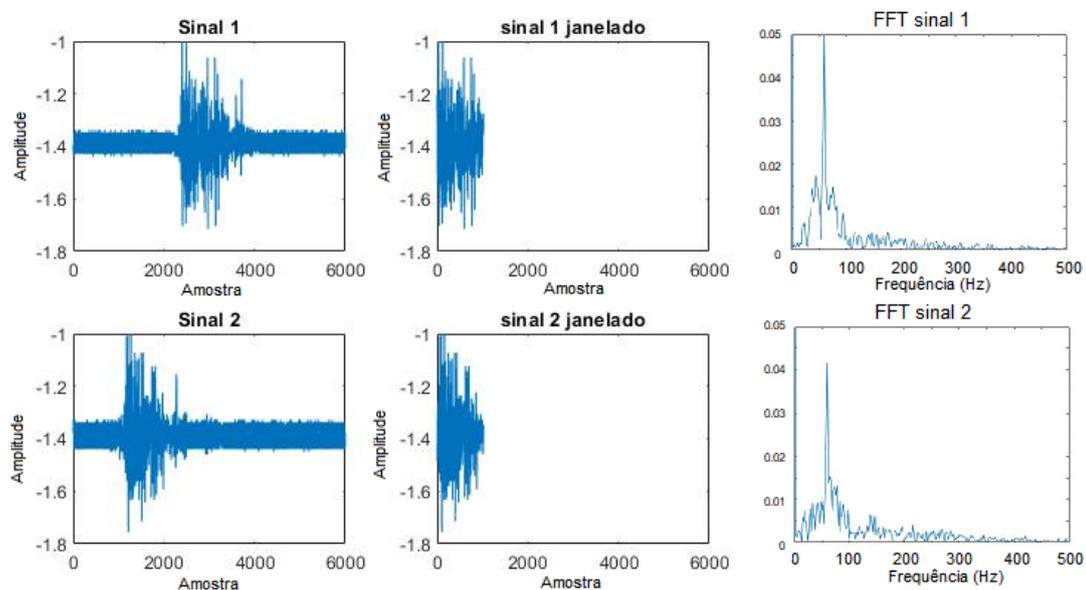
As configurações principais para o treinamento das redes PMC foram: aprendizagem supervisionada com algoritmo de aprendizado *Levenberg-Marquardt backpropagation*, função de ativação logística para os neurônios das camadas escondidas e função de ativação linear para a camada de saída da rede.

Algumas configurações foram testadas, conforme o tamanho da janela temporal, a função *wavelets* e a topologia da RNA. Os tamanhos das janelas foram 1024 e 2048 amostras. As funções *wavelets* foram: *Daubechies* de ordem 5 e *Daubechies* de ordem 10. As RNAs foram de uma, duas ou três camadas escondidas, com diferentes quantidades de neurônios em cada camada escondida.

### 3 RESULTADOS

Na Fig. 2 são apresentados dois sinais de contração do dedo anelar. Na esquerda estão os dois sinais (Sinal 1 e Sinal 2) dentro de uma janela temporal de 3 segundos. No centro os sinais estão janelados ulteriormente em 1024 amostras, nos instantes quando identifica-se a contração muscular. E na direita estão as Transformadas rápidas de Fourier (FFT) dos sinais de 1024 amostras.

Figura 2 – Sinais correspondentes à contração do dedo anelar



Fonte: Autoria própria (2020).



O sistema foi analisado em função da topologia e quantidade de neurônios em cada camada escondida. Nos testes de RNAs de uma única camada escondida, as quantidades de neurônios utilizados foram: 5, 10, 15, 20, 25, 30, 35, 40, 45. Esses testes tiveram resultados insatisfatórios, ou seja, taxas de acertos abaixo de 70 %, não sendo observada uma variação significativa na taxa de acertos em função da quantidade de neurônios. Inferiu-se que o aumento indiscriminado de neurônios, mantendo apenas uma camada escondida, não melhoraria os resultados. Outras topologias de redes PMC com 2 e 3 camadas escondidas foram testadas, conforme a Tab. 1.

As acurácias de classificação para os sinais janelados em 1024 e 2048 amostras podem ser comparadas pelas Tab. 2 e Tab. 3. Esses testes não mostraram resultados tão discrepantes. As acurácias de classificação para as funções *wavelets Daubechies* ordem 10 e *Daubechies* ordem 5, com sinais de 1024 amostras, podem ser comparadas pelas Tab. 2 e Tab. 4.

**Tabela 1 – Topologias de Redes Neurais Artificiais Perceptron Multicamadas testadas**

Nº da RNA	Quantidade de neurônios 1ª Camada Escondida	Quantidade de neurônios 2ª Camada Escondida	Quantidade de neurônios 3ª Camada Escondida
1	10	5	0
2	15	10	0
3	20	15	0
4	25	20	0
5	30	25	0
6	35	30	0
7	40	35	0
8	15	10	5
9	20	15	10
10	25	20	15

Fonte: Autoria própria (2020).

**Tabela 2 – Testes dos sinais de 1024 amostras decompostos por Transformada de Wavelet da família Daubechies ordem 10**

	RNA1	RNA2	RNA3	RNA4	RNA5	RNA6	RNA7	RNA8	RNA9	RNA10
Média de erros	9.4	11	9	9.4	9.4	10.8	8.4	12	11.6	11
Taxa de acertos	79,1%	75,6%	80,0%	79,1%	79,1%	76,0%	81,3%	73,3%	74,2%	75,6%

Fonte: Autoria própria (2020).

**Tabela 3 – Testes dos sinais de 2048 amostras decompostos por Transformada Wavelet da família Daubechies ordem 10**

	RNA1	RNA2	RNA3	RNA4	RNA5	RNA6	RNA7	RNA8	RNA9	RNA10
Média de erros	14.8	9.8	9.4	10.4	11.8	8.4	9.6	11.8	11.6	10.8
Taxa de acertos	67,1%	78,2%	79,1%	76,9%	73,8%	81,3%	78,7%	73,8%	74,2%	76,0%

Fonte: Autoria própria (2020).

**Tabela 4 – Testes dos sinais de 1024 amostras decompostos por Transformada Wavelet da família Daubechies ordem 5**

	RNA1	RNA2	RNA3	RNA4	RNA5	RNA6	RNA7	RNA8	RNA9
Média de erros	11.8	8.8	9.6	7.8	9.6	9.2	9.4	10.4	10.8
Taxa de acertos	73,8%	80,4%	78,7%	82,7%	78,7%	79,6%	79,1%	76,9%	76,0%

Fonte: Autoria própria (2020).

A partir das taxas de acertos das Tab. 2, Tab. 3 e Tab. 4, a topologia que apresentou resultados melhores, ou seja, a maior média da taxa de acertos, foi a RNA número 7 com duas camadas escondidas de 40 e 35 neurônios, respectivamente, na primeira e na segunda camada escondida.



Nenhuma dessas redes apresentou um treinamento com duração superior a 30 segundos, a maioria demandou menos de 10 segundos. Em operação, o sistema com sinais de 1024 amostras demora menos de 1 segundo para classificar o sinal que está chegando.

#### 4 CONCLUSÕES

A abordagem baseada em *wavelets* e RNA do tipo PMC para classificação de padrões em sinais de EMG, coletados com um único par de eletrodos, exibe uma acurácia acima da meta inicial de 75 %. Essa acurácia está abaixo das alcançadas por (HUDGINS; PARKER, P.; SCOTT, 1993) e (ENGLEHART; HUDGINS; PARKER, P. A., 2001), mas o sistema desenvolvido pode ser otimizado seja na aquisição que na classificação, concedendo boas esperanças para uma aplicação com essas técnicas.

#### AGRADECIMENTOS

Agradeço ao Prof. Dr. Paulo Rogério Scalassara pela grande disponibilidade em me orientar, pela disponibilização do laboratório, das ferramentas e dos equipamentos, e por toda a paciência que teve para me acompanhar nesse trabalho.

#### REFERÊNCIAS

- DA SILVA, Ivan Nunes; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes Neurais Artificiais para engenharia e ciências aplicadas curso prático**. São Paulo: Artliber, 2010.
- DINIZ, Paulo SR; SILVA, Eduardo AB da; NETTO, Sergio L. **Processamento Digital de Sinais: Projeto e Análise de Sistemas**. Porto Alegre: Bookman, 2014.
- ENDERLE, John D.; BRONZINO, Joseph D.; BLANCHARD, Susan M. **Introduction to Biomedical Engineering**. Amsterdam: Elsevier Academic Press, 2005.
- ENGLEHART, Kevin; HUDGINS, Bernard; PARKER, Philip A. A wavelet-based continuous classification scheme for multifunction myoelectric control. **IEEE Transactions on Biomedical Engineering**, v. 48, n. 3, p. 302–311, 2001. DOI: [10.1109/10.914793](https://doi.org/10.1109/10.914793).
- HUDGINS, B.; PARKER, P.; SCOTT, R. N. A new strategy for multifunction myoelectric control. **IEEE Transactions on Biomedical Engineering**, v. 40, n. 1, p. 82–94, 1993. DOI: [10.1109/10.204774](https://doi.org/10.1109/10.204774).
- PARKER, Philip A; SCOTT, Robert N. Myoelectric control of prostheses. **Critical Reviews in Biomedical Engineering**, v. 13, n. 4, p. 283–310, 1986.
- PARKER, Philip A; STULLER, John A; SCOTT, Robert N. Signal processing for the multistate myoelectric channel. **Proceedings of the IEEE**, v. 65, n. 5, p. 662–674, 1977.
- VETTERLI, M.; HERLEY, C. Wavelets and filter banks: relationships and new results. **International Conference on Acoustics, Speech, and Signal Processing**, Albuquerque, v. 3, p. 1723–1726, 1990. DOI: [10.1109/ICASSP.1990.115812](https://doi.org/10.1109/ICASSP.1990.115812).
- WEBSTER, John G; NIMUNKAR, Amit J. **Medical Instrumentation: Application and Design**. Madison: John Wiley & Sons, 2020.