

Sistema de Aquisição de Sinais Mioelétricos e Detecção de Movimentos dos Dedos Usando Wavelets e Redes Neurais Artificiais

Ayrton Correia Guedes,* Paulo Rogério Scalassara,* Wagner Endo*

* *Departamento Acadêmico da Elétrica, Universidade Tecnológica
Federal do Paraná (UTFPR), (e-mails: cguedesayrton@gmail.com,
[prscalassara, wendo]@utfpr.edu.br).*

Abstract: This paper describes the development of a system for myoelectric signal acquisition from a person's forearm that also classifies finger movements from features obtained in the frequency domain. Three electromyography surface electrodes were employed, two for the signals and one for reference. They were connected to a system composed of circuits for acquisition, conditioning, digitalization, and processing of the signals. The interface with the electrodes was performed by an analog circuit based on an instrumentation amplifier in a feedback loop with the person's body, along with a lowpass active filter composed of operational amplifiers. A commercial digital acquisition device performed the conversion from analog to digital signals. The signal processing was composed of a temporal windowing, wavelet transform decomposition, estimation of the energies and entropies of the wavelet coefficients, and classification by multilayer perceptron artificial neural networks. During the method evaluation, we tested variations of wavelet filter and time window lengths and several neural network topologies to identify the most significant parameters for signal classification. As a result, after selecting the best window and filter lengths, the tested topologies presented accuracy rates between 73% and 83% for the classification of the five types of finger movements.

Resumo: Este artigo descreve o desenvolvimento de um sistema de aquisição de sinais mioelétricos coletados do antebraço de uma pessoa e classificação dos movimentos dos dedos a partir de atributos obtidos no domínio da frequência. Utilizam-se três eletrodos de superfície para eletromiografia, dois de sinal e um de referência, conectados a um sistema de coleta composto por circuitos de aquisição, condicionamento, digitalização e processamento digital de sinais. A interface com os eletrodos é realizada por um circuito analógico, o qual utiliza um amplificador de instrumentação em uma malha de realimentação com o corpo da pessoa, em conjunto com um filtro ativo passa-baixas com amplificadores operacionais. Em seguida, a conversão do sinal analógico para digital é feita por um dispositivo digitalizador dos sinais comercial. Já o processamento dos sinais é composto, primeiramente, por um janelamento temporal, seguido por decomposição usando transformada *wavelet*, obtenção de atributos dos sinais usando energias e entropias dos coeficientes *wavelet*, finalizando com classificação por redes neurais artificiais do tipo *perceptron* multicamadas. Nos ensaios, analisaram-se variações do comprimento do filtro *wavelet*, tamanho da janela temporal e diversas topologias das redes neurais, de forma a se entender melhor quais parâmetros são mais significativos na classificação dos sinais. Como resultado, após a escolha das melhores configurações das janelas e filtros, as topologias testadas apresentaram acurácias entre 73% e 83% na classificação dos cinco tipos de movimentos dos dedos.

Keywords: Electromyography; finger movement; pattern recognition; wavelet transform; artificial neural networks; multilayer perceptron.

Palavras-chaves: eletromiografia; movimento dos dedos; reconhecimento de padrões; transformada wavelet; redes neurais artificiais; perceptron multicamadas.

1. INTRODUÇÃO

Sistemas para aquisição de sinais de eletromiografia (EMG) com eletrodos de superfície da pele são utilizados em muitas aplicações, incluindo diagnóstico clínico, próteses de assistência motora para indivíduos com deficiências e em tratamentos por estimulação elétrica funcional (Fang et al., 2015). A ideia é que o sinal de EMG de superfície pode conter informações referentes às contrações musculares subjacentes. Assim, realizam-se análises das amplitudes ou taxas de variações desses sinais para determinar os estados dos músculos e movimentos desejados (Hudgins et al., 1993; Parker and Scott, 1986). Para isso, assume-se que o sinal pode ser descrito por um conjunto de parâmetros que é repetível para um dado estado de ativação muscular e distinto dos parâmetros de outros estados.

Diversos métodos e algoritmos de reconhecimento de padrões e processamento de sinais são utilizados para as análises de sinais de EMG, os quais são essencialmente unidimensionais. Em aplicações de detecção de movimentos, a informação extraída dos sinais é representada por um conjunto de atributos e escolhida de tal forma a minimizar o erro de classificação, buscando maximizar a separação das classes de movimentos. Uma vez que o conjunto de características tenha sido escolhido, um classificador de padrões adequado pode ser usado para a determinação da classe (Hudgins et al., 1993).

Nos últimos anos, diversas pesquisas focam no desenvolvimento de sistemas baseados em sinais de EMG, especialmente para controle de próteses para pessoas amputadas, obtendo relativo sucesso e mostrando diversas limitações ainda existentes (Okuno et al., 2005). Especificamente para as mãos, objetiva-se detectar qual movimento a pessoa deseja realizar baseado somente em sinais eletromiográficos coletados nos músculos do antebraço.

Em trabalhos recentes sobre movimentos de mão, como em aplicações com próteses, busca-se determinar qual dedo se deseja mover com base em sinais de EMG do braço. Para isso, geralmente são usados métodos de aprendizagem de máquina, como redes neurais, máquinas de vetores de suporte ou árvores de decisão (Kumar et al., 2022). Como entradas, utilizam-se atributos obtidos dos sinais usando técnicas de análise tempo-frequência, como transformadas wavelets (Duan et al., 2016; Côté-Allard et al., 2019), ou mesmo outras redes neurais para extração automática de características (Luu et al., 2022; Dong et al., 2022).

Nessa mesma linha, o objetivo deste estudo é propor, como originalmente desenvolvido em Guedes (2021), a utilização de extração de características com transformada *wavelet* combinada com classificador neural para se obter uma correspondência entre a flexão individual de cada dedo da mão e os sinais de EMG detectados na superfície do antebraço. Porém, além do software de detecção, foca-se também no desenvolvimento do sistema de aquisição de sinais de um único canal de EMG utilizando componentes de baixo custo quando comparados com soluções comerciais, as quais possuem elevado valor agregado.

Após esta breve introdução, na próxima seção, apresentam-se informações sobre a aquisição de sinais de EMG, especificamente sobre os circuitos usados nesse processo. Em

seguida, em Materiais e Métodos, discutem-se a metodologia empregada neste estudo e o sistema desenvolvido para captura e processamento dos sinais. Depois, na seção seguinte, apresentam-se os resultados dos ensaios com diversas topologias de redes neurais. Por fim, as conclusões são apresentadas na última seção do texto.

2. AQUISIÇÃO DE SINAIS DE EMG

Células nervosas e musculares geram sinais bioelétricos que resultam em mudanças eletroquímicas dentro e entre as células. Se uma célula muscular receber um estímulo que supere um determinado limiar, ela gerará um potencial de ação. Se muitas células são ativadas, um campo elétrico é gerado que se propaga através do tecido biológico. Esse campo elétrico, que provém do sistema nervoso periférico através dos neurônios motores, pode ser considerado um sinal (Bansal, 2021; Enderle et al., 2005).

O sinal de EMG, que é um exemplo desse fenômeno, é o sinal de controle muscular do corpo humano que contém a informação de uma contração muscular. A detecção desse sinal pode ser feita por meio de eletrodos inseridos no tecido muscular ou na superfície da pele próximo do músculo de interesse (Webster, 2009).

O mecanismo de condutividade elétrica no corpo envolve íons e portadores de carga. Assim, captar sinais bioelétricos envolve interagir com esses portadores de carga iônica e fazer a transdução de correntes iônicas para elétricas, o que é feito por eletrodos (Bronzino, 2000; Xu et al., 2017).

Os sinais de EMG apresentam variação de amplitude em função da posição dos eletrodos e entre indivíduos, devido à natureza desses sinais. Além disso, a estrutura no padrão da forma de onda para contrações que produzem diferentes movimentos do membro é distinta (Hudgins et al., 1993). Geralmente, a amplitude dos sinais varia entre 0 e 10 mV_{pp} e a energia é limitada entre 0 Hz e 500 Hz, com dominância entre 50 Hz e 150 Hz (Enderle et al., 2005; Webster, 2009).

Em Hudgins et al. (1993), a aquisição dos sinais de EMG foi realizada usando um par de eletrodos. Para amplificação, usou-se um amplificador padrão para sinais mioelétricos, com entrada diferencial isolada e ganho de 5000. A taxa de amostragem foi 1 kHz e os sinais considerados correspondiam aos primeiros 500 ms do início da contração. Já em Englehart et al. (2001), foram utilizados quatro pares de eletrodos, sendo espaçados entre si em 2 cm e posicionados sobre o antebraço. Cada registro possuía a duração de 256 ms, com frequência de amostragem de 1 kHz e filtragem entre 10 e 500 Hz.

Devido às características dos sinais de EMG, o circuito de amplificação deve possuir as seguintes propriedades: amplificação adequada, elevada razão de rejeição de modo comum (CMRR), baixa corrente de polarização de entrada, baixa tensão de *offset*, baixa variação dessa tensão e alta impedância de entrada (Marchetti and Duarte, 2011).

Uma configuração comum para o circuito de amplificação utiliza um amplificador de instrumentação (in-amp) comercial ou pode-se construir um in-amp usando três amplificadores operacionais (amp-ops), como mostra a Figura 1. Com esse circuito, o sinal de modo comum é rejeitado, enquanto que o sinal diferencial é amplificado.

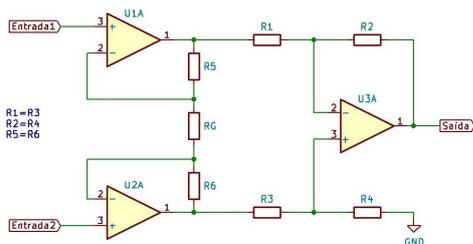


Figura 1. Circuito amplificador com elevada CMRR do tipo in-amp construído com três amp-ops.

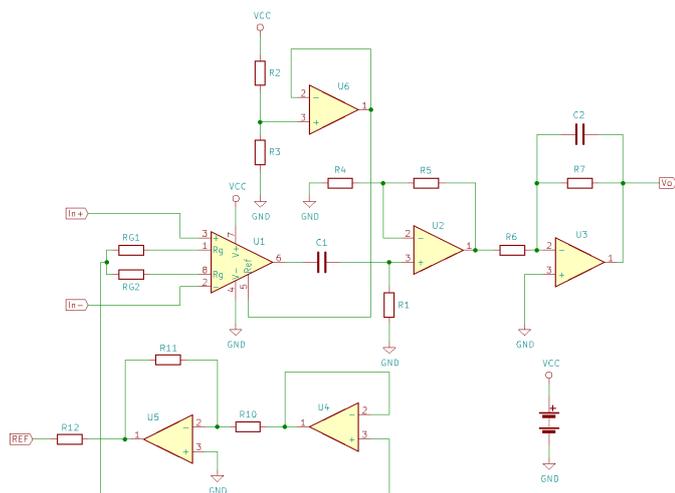


Figura 2. Modelo de circuito de aquisição de sinais de EMG (Guedes, 2021).

Nesse circuito, o amp-op U3A e os resistores R1, R2, R3 e R4 operam como amplificador subtrator, enquanto a parte composta pelos amp-ops U1A e U2A e pelos resistores R5, RG e R6 opera como seguidores de tensão. O seguidor de tensão passa o sinal de modo comum com ganho unitário sem nenhuma alteração. Na seção do subtrator, o sinal de modo comum é rejeitado e o sinal diferencial é amplificado, com ganho definido pela razão dos resistores R2 e R1.

Observa-se que na implementação deste circuito com componentes discretos é relativamente difícil possuir resistores perfeitamente casados para respeitar as condições de igualdade de resistências $R1 = R3$, $R2 = R4$ e $R5 = R6$. O descasamento entre os resistores resulta em diminuição da CMRR, enquanto que nos in-amps, as resistências são acertadas para serem o mais possivelmente casadas, além da integração de outros dispositivos para proteção contra sobretensão e otimização do circuito integrado (Moleta and Dobgenski, 2007). Nos in-amps comerciais, como o AD620, utilizado neste trabalho, a CMRR passa de 100 dB, enquanto que usando amp-ops, chega-se a 90 dB no máximo.

Após o in-amp, usa-se um filtro para eliminar as faixas de frequências indesejadas. Um circuito modelo com dois eletrodos de entrada (In+ e In-), um canal de EMG, mais um eletrodo de referência (REF) é apresentado na Figura 2 (Moleta and Dobgenski, 2007; Guedes, 2021).

Nesse circuito, usa-se um in-amp com duas etapas de filtragem, através de um filtro passa-altas e outro passa-baixas. O circuito constituído pelos amp-ops U4 e U5 e pelos resistores R10, R11 e R12 é um circuito de controle

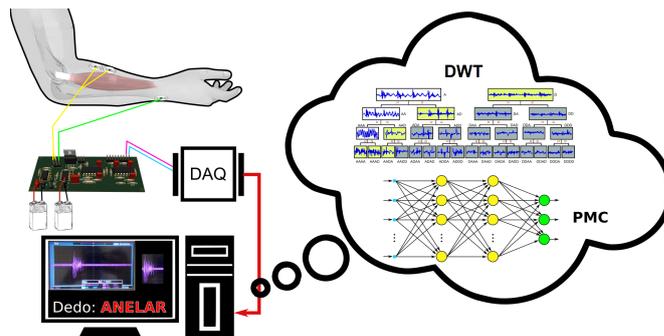


Figura 3. Metodologia proposta (Guedes, 2021).

da tensão de modo comum no eletrodo de referência. Com essa configuração, se a tensão de modo comum presente no corpo da pessoa aumentar ou diminuir, o valor de tensão entre RG1 e RG2 será alterado proporcionalmente. O primeiro amp-op funciona como buffer de ganho unitário e o segundo como inversor. Esse bloco amplifica e inverte essa tensão e, através de um resistor de isolamento (para garantir a segurança da pessoa), injeta de volta esta tensão no eletrodo de referência, corrigindo a tentativa de variação da tensão de entrada (Pfrimer, 2009).

Na próxima seção, serão apresentados mais detalhes do circuito projetado e da metodologia para detecção dos movimentos dos dedos a partir dos sinais de EMG.

3. MATERIAIS E MÉTODOS

A metodologia proposta consiste em desenvolver um circuito de aquisição de sinais de EMG, como descrito na seção anterior e em Guedes (2021). Também, propor um sistema de detecção de movimento dos dedos usando extração de características por decomposição com transformada *wavelet* discreta (DWT) e classificação usando redes neurais do tipo *perceptron* multicamadas (PMC), Figura 3.

O circuito analógico de aquisição e condicionamento de sinais, que realiza a amplificação e filtragem, foi 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 os sinais para cobrir ao máximo o fundo de escala do dispositivo de digitalização de sinal.

O filtro foi projetado a partir de especificações de frequência de corte, *ripple* na faixa de passagem, faixa da banda de rejeição e atenuação nessa banda. Para o circuito amplificador, usou-se o amp-in AD620, o qual possui uma alta CMRR e permite o ajuste do ganho de tensão simplesmente com uma resistência entre dois terminais. Com relação ao filtro passa-banda, implementou-se um filtro composto por um passa-altas do tipo RC (resistor-capacitor) de primeira ordem, para retirada do *offset*, em cascata com um passa-baixas Chebyshev ativo (com op-amps) de quinta ordem para retirada do ruído de frequências altas. O filtro apresentou banda de passagem entre 7 e 1112 Hz.

O esquemático do filtro passa-baixas é apresentado na Figura 4 e o esquemático do circuito de aquisição, amplificação, realimentação negativa e filtro passa-altas na Figura 5. O *layout* da placa de circuito impresso do sistema de aquisição é apresentado na Figura 6.

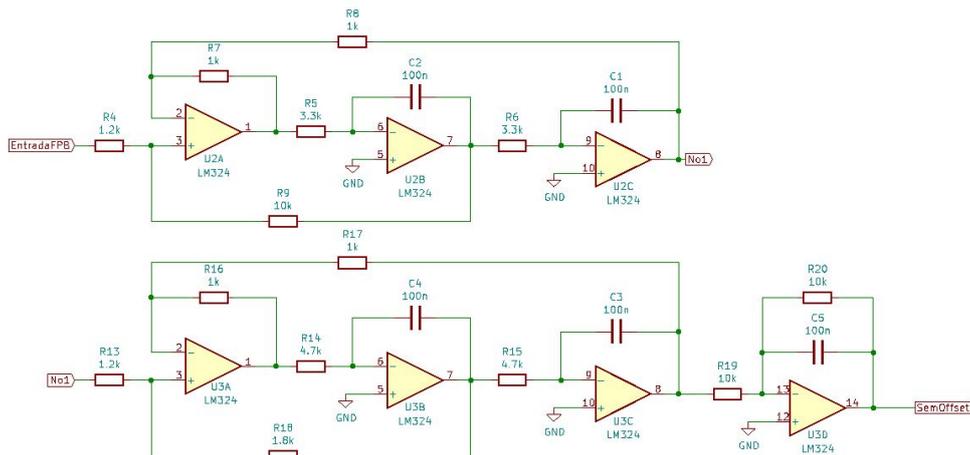


Figura 4. Esquemático do filtro passa-baixa Chebyshev de 5a. ordem projetado para a aquisição de sinais de EMG.

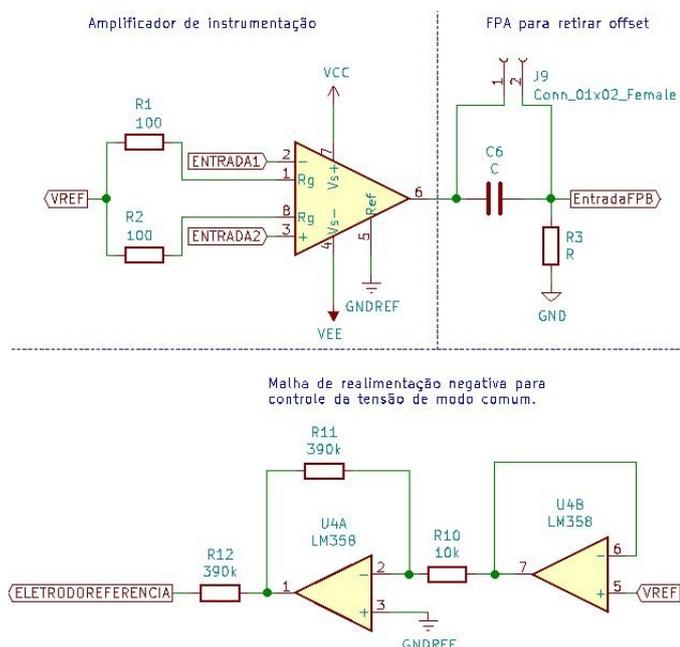


Figura 5. Circuito de aquisição do sinal de EMG e realimentação do sinal de referência.

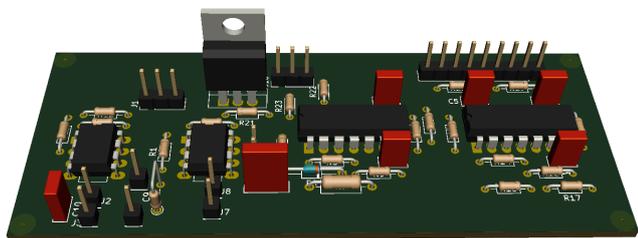


Figura 6. Layout da placa de circuito impresso do sistema de aquisição de sinais de EMG.

As aquisições dos sinais de EMG foram realizadas em um dos autores deste estudo durante contrações individuais de cada dedo da mão. Usaram-se eletrodos de superfície Ag/AgCl com gel eletrolítico, cabos blindados e o circuito analógico de aquisição anterior. O sinal diferencial de entrada é coletado de dois eletrodos fixados na parte interna do antebraço mais próxima do cotovelo do que do

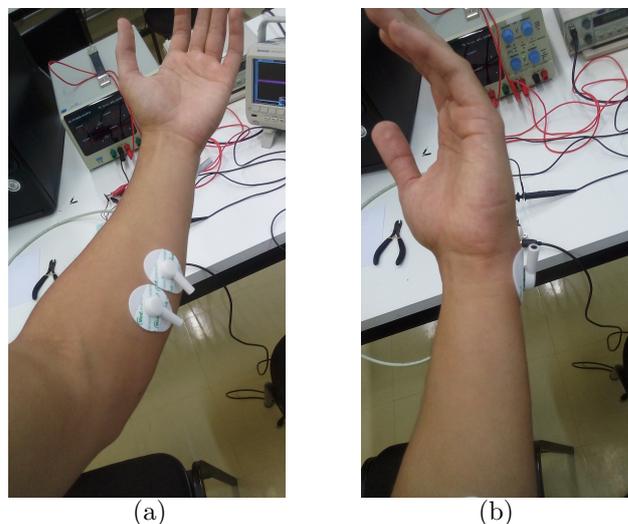


Figura 7. Fotos das posições de (a) eletrodos para coleta do sinal de EMG e (b) eletrodo de referência.

punho, onde há um volume muscular maior. Um terceiro eletrodo, posicionado sobre uma região óssea do antebraço próxima da mão (ou cotovelo), permite ter uma referência para o circuito de realimentação. A Figura 7 ilustra a posição utilizada dos eletrodos para captura dos sinais.

O processamento digital de sinais foi realizado no software MATLAB. Para isso, usou-se o dispositivo digitalizador de sinais (DAQ) USB-6008 da National Instruments, o qual foi conectado entre a saída da placa de condicionamento dos sinais e um computador. Para cada dedo, foram registrados 29 sinais de contração individual, totalizando 145 sinais. Esses foram divididos em dois grupos, um grupo de treinamento com 100 sinais (20 de cada dedo) e um grupo de teste com 45 sinais (9 de cada dedo).

O algoritmo desenvolvido detecta automaticamente o começo da contração muscular pelo aumento da amplitude do sinal de EMG, ou seja, a parte com mais energia. Realizou-se captura do sinal durante três segundos com frequência de amostragem de 2 kHz. Na prática, foram testados sinais janelados em 1024 e 2048 amostras.

Na Figura 8 (a) e (d), mostram-se dois sinais de EMG de contração do dedo anelar e indicador respectivamente, am-

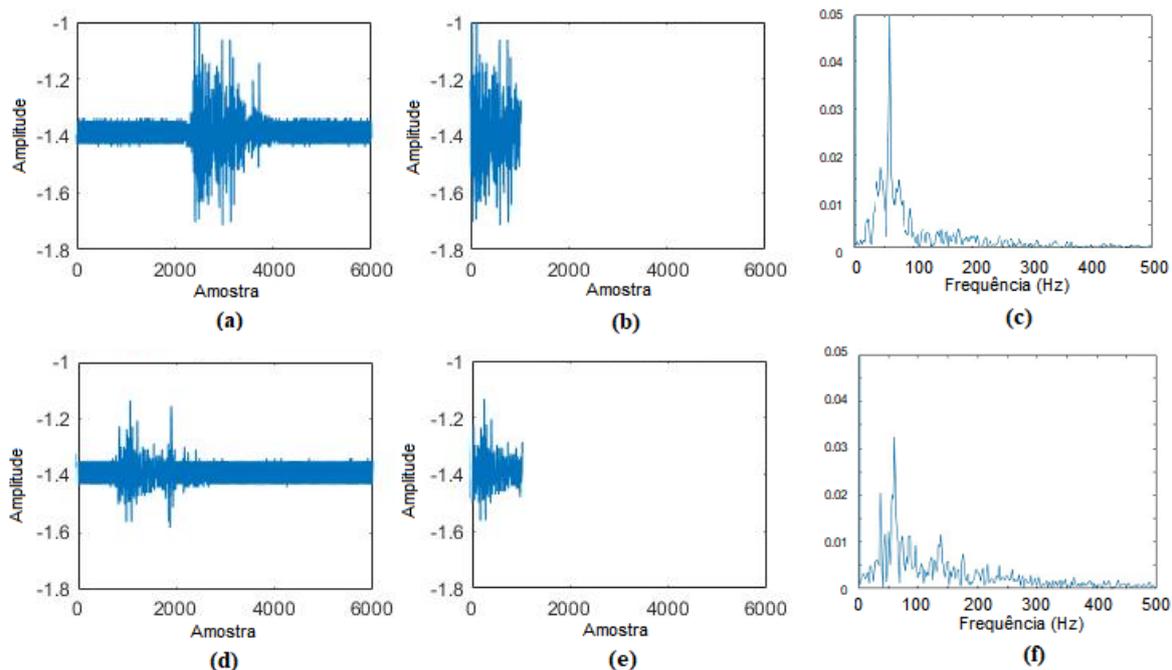


Figura 8. Sinais de EMG correspondentes à contração dos dedos anelar e indicador. (a) Sinal com duração de três segundos da contração do dedo anelar. (b) Janelamento de 1024 pontos do sinal anterior. (c) Espectro de frequências do sinal janelado anterior. (d) Sinal com duração de três segundos da contração do dedo indicador. (e) Janelamento de 1024 pontos do sinal anterior. (f) Espectro de frequências do sinal janelado anterior.

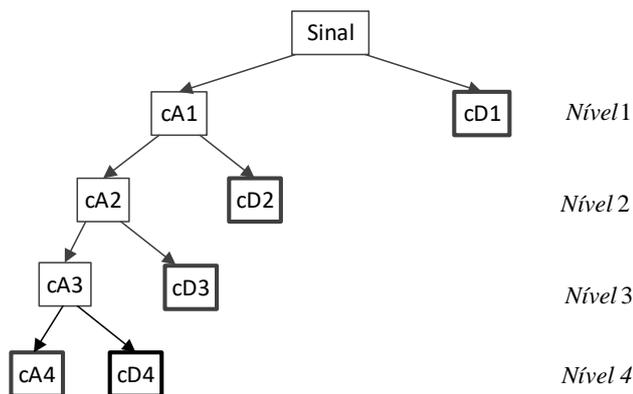


Figura 9. Árvore de decomposição DWT até o quarto nível indicando os componentes cD1, cD2, cD3, cD4 e cA4.

bos com duração de três segundos. Em (b) e (e), mostram-se os resultados do janelamento com 1024 amostras dos sinais anteriores. Por fim, em (c) e (f), apresentam-se os módulos dos espectros de frequência (até 500 Hz) dos sinais janelados usando transformadas de Fourier.

Os sinais janelados são decompostos com DWT até o quarto nível, usando a família Daubechies, resultando em quatro componentes de detalhes e um de aproximação, cD1, cD2, cD3, cD4 e cA4 respectivamente (Diniz et al., 2014). A Figura 9 ilustra simplificada essa decomposição com a DWT e os componentes resultantes.

De forma complementar, a Figura 10 apresenta os componentes cD1, cD2, cD3, cD4 e cA4 para os sinais da Figura 8. Em (a), mostram-se os componentes do sinal de EMG com 1024 amostras referente à contração do dedo anelar. Em

(b), mostram-se os mesmos componentes para o sinal com 1024 amostras da contração do dedo indicador.

Com metodologia similar ao apresentado em Santos et al. (2020), usaram-se os valores de energia e entropia dos componentes da decomposição DWT como entradas da rede PMC, resultando em vetores com 10 atributos por sinal. A PMC é uma topologia de redes neurais composta por neurônios artificiais totalmente conectados com uma camada de entrada (dada pelos vetores de atributos), pelo menos uma camada escondida e uma camada de saída, como ilustrado na Figura 11 (Silva et al., 2016).

Foram testadas diferentes topologias de redes PMC para a classificação dos sinais de EMG, variando-se a quantidade de camadas escondidas, de uma a três, e o número de neurônios de cada uma. Para o treinamento das redes, usou-se algoritmo de aprendizado *backpropagation* com técnica Levenberg-Marquardt, além de funções de ativação logísticas para os neurônios das camadas escondidas e lineares para a camada de saída.

Na próxima seção, apresentam-se os resultados dos ensaios usando as diversas topologias de classificadores PMC.

4. RESULTADOS

Nesta seção, apresentam-se os resultados de ensaios variando alguns parâmetros do sistema de classificação: tamanho da janela temporal, 1024 ou 2048 amostras; ordem do filtro *wavelet* Daubechies, 10 ou 20 (db5 e db10 no MATLAB), e topologia da rede PMC, com uma, duas ou três camadas escondidas e diferentes quantidades de neurônios em cada camada escondida.

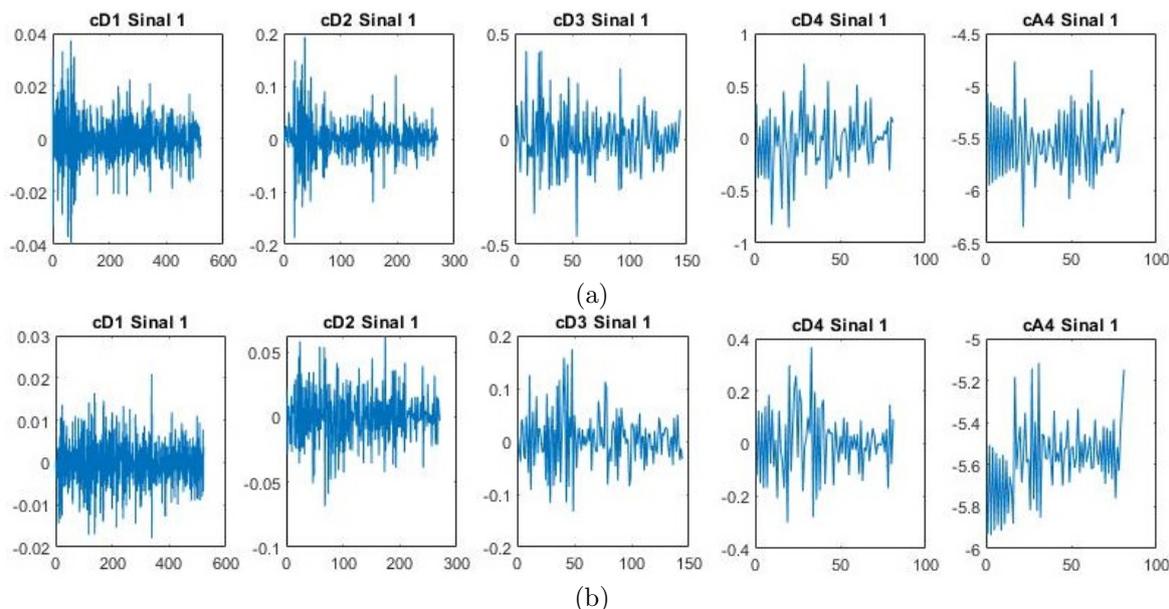


Figura 10. Componentes da decomposição DWT dos sinais da Figura 8 usando filtros Daubechies de ordem 20. Na parte (a), mostram-se, respectivamente, os componentes cD1, cD2, cD3, cD4 e cA4 do sinal de EMG referente à contração do dedo anelar após janelamento com 1024 amostras. Na parte (b), mostram-se os mesmos componentes para o sinal de EMG janelado da contração do dedo indicador.

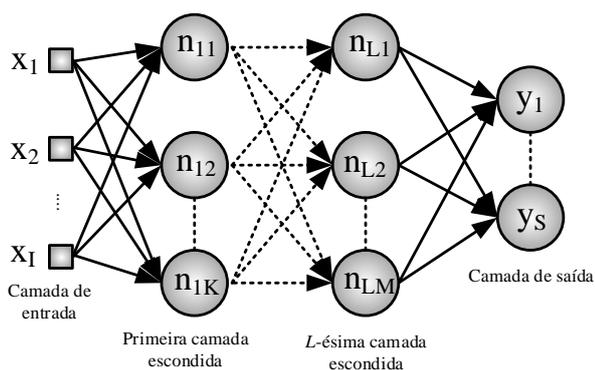


Figura 11. Ilustração da estrutura de uma rede neural do tipo *perceptron* multicamadas.

Como já mencionado, para os ensaios com as redes neurais, usaram-se 100 sinais de EMG para treinamento (20 de cada dedo) e 45 sinais para teste (9 de cada dedo), sendo feitos cinco ensaios para cada configuração.

Com relação às topologias das redes, inicialmente, considerou-se somente uma camada escondida com as seguintes quantidades de neurônios: 5 a 45, de 5 em 5. Esses ensaios obtiveram taxas de acertos de classificação abaixo de 70%. Não foi observada variação significativa nessa taxa em função da quantidade de neurônios, tamanho da janela ou ordem do filtro *wavelet*. Em seguida, usaram-se redes com duas e três camadas escondidas, conforme a Tabela 1, as quais apresentaram variação das taxas de acerto.

Com base nessas topologias de rede, analisou-se a modificação da quantidade de amostras da janela que contém o trecho de contração do sinal de EMG. Usou-se filtro *wavelet* Daubechies de ordem 20. As quantidades de erros (em relação a 45 sinais de teste) e acurácias de classificação

Tabela 1. Topologias das redes em função do número de neurônios nas camadas escondidas.

Rede	Quantidade de neurônios por camada		
	1a. cam	2a. cam	3a. cam
R1	10	5	-
R2	15	10	-
R3	20	15	-
R4	25	20	-
R5	30	25	-
R6	35	30	-
R7	40	35	-
R8	15	10	5
R9	20	15	10
R10	25	20	15

médias para os ensaios usando sinais com 1024 e 2048 amostras são apresentadas nas Tabelas 2 e 3 respectivamente. Com base nas acurácias médias, percebe-se que os resultados são similares para as duas configurações. Assim, por simplicidade, opta-se por utilizar janelamento com 1024 amostras, obtendo classificadores menos complexos.

Também foi realizada uma comparação da acurácia de classificação das redes da Tabela 1 quando se usava os filtros *wavelet* da família *Daubechies* com comprimentos 10, ao invés de 20, para a decomposição dos sinais com 1024 amostras. A Tabela 4 apresenta o resultado desse novo ensaio, podendo-se comparar com o apresentado na Tabela 2 para filtro de comprimento 20.

Comparando-se os resultados, novamente, observa-se que as acurácias das redes foram similares. Assim, a diferença da ordem dos filtros não teve impacto relevante, acurácias em torno de 73 e 83%, sendo o melhor resultado, 82,7%, obtido pela rede R4 com filtro de comprimento 10. Por isso, analisa-se essa rede com mais detalhes, usando filtros *wavelet* de comprimento 10 e janelas de 1024 amostras.

Tabela 2. Quantidade de erros e acurácia média para os ensaios com as redes PMC usando janelamento com 1024 amostras e filtro *wavelet* Daubechies de ordem 20.

Ensaio	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10
1	12	14	9	9	9	12	7	16	12	15
2	11	10	7	10	10	10	7	12	10	13
3	8	10	8	8	8	10	6	10	11	9
4	9	13	11	9	11	10	15	7	15	9
5	7	8	10	11	9	12	7	15	10	9
Média	9,4	11	9	9,4	9,4	10,8	8,4	12	11,6	11
Acurácia	79,1%	75,6%	80,0%	79,1%	79,1%	76,0%	81,3%	73,3%	74,2%	75,6%

Tabela 3. Quantidade de erros e acurácia média para os ensaios com as redes PMC usando janelamento com 2048 amostras e filtro *wavelet* Daubechies de ordem 20.

Ensaio	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10
1	10	10	9	13	12	10	7	9	9	13
2	27	10	7	8	9	7	11	13	15	13
3	13	6	8	13	9	8	10	14	12	12
4	13	10	13	9	13	9	8	15	11	8
5	11	13	10	9	16	8	12	8	11	8
Média	14,8	9,8	9,4	10,4	11,8	8,4	9,6	11,8	11,6	10,8
Acurácia	67,1%	78,2%	79,1%	76,9%	73,8%	81,3%	78,7%	73,8%	74,2%	76,0%

Tabela 4. Quantidade de erros e acurácia média para os ensaios com as redes PMC usando janelamento com 1024 amostras e filtro *wavelet* Daubechies de ordem 10.

Ensaio	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10
1	11	11	7	9	12	10	8	14	9	9
2	10	7	9	8	8	10	8	12	12	11
3	16	9	9	7	8	7	12	11	12	10
4	12	8	11	6	7	9	8	9	13	13
5	10	9	12	9	13	10	11	6	8	8
Média	11,8	8,8	9,6	7,8	9,6	9,2	9,4	10,4	10,8	10,2
Acurácia	73,8%	80,4%	78,7%	82,7%	78,7%	79,6%	79,1%	76,9%	76,0%	77,3%

Realizaram-se cinco ensaios com essa configuração sendo 100 sinais para treinamento e 45 sinais para testes. As acurácias resultantes foram 80% (em três ensaios), 82,2% e 77,8%, equivalentes às seguintes quantidade de erros: 9, 9, 9, 8 e 10, totalizando 45 casos. A Tabela 5 apresenta uma matriz de confusão, com somente os casos incorretos totalizados desses ensaios, indicando quais contrações dos dedos foram confundidas pelo classificador.

Tabela 5. Matriz de confusão para rede R4, janela de 1024 amostras e filtro *wavelet* de ordem 10 (db5). Somente os casos incorretos.

Classe	Verdadeira				
	anelar	indicador	médio	mindinho	polegar
anelar		8		22	
indicador					
médio			14		
mindinho					
polegar		1			

Observa-se a maior quantidade de erros de classificação na atribuição do dedo anelar para sinais de contração dos dedos indicador (8 casos) e mindinho (22 casos). Já o dedo médio foi confundido 14 vezes como mindinho e um único caso de indicador confundido como polegar.

Para comparação, fez-se esses ensaios usando janelas de 1024 amostras e a rede R7, a qual apresentou a segunda maior acurácia média, como visto na Tabela 2, porém agora com filtros *wavelet* de comprimento 10. As quantidades de erros foram: 8, 8, 10, 10 e 11, respectivamente, 82,2%

(8 erros), 77,8% (10 erros) e 75,6% (11 erros), totalizando 47 casos. A matriz de confusão é apresentada na Tabela 6.

Tabela 6. Matriz de confusão para rede R7, janela de 1024 amostras e filtro *wavelet* de ordem 10 (db5). Somente os casos incorretos.

Classe	Verdadeira				
	anelar	indicador	médio	mindinho	polegar
anelar		10		24	
indicador				1	
médio			9	2	
mindinho					
polegar				1	

Nesta topologia, os erros se concentraram nos sinais de contração do erro mindinho, sendo 24 casos erroneamente classificados como dedo anelar, 1 como indicador, 2 como médio e 1 como polegar. Também apresentaram-se 10 casos de dedo indicador classificado como anelar e 9 casos de dedo médio confundido por mindinho.

5. CONCLUSÃO

Neste trabalho, apresentou-se o desenvolvimento de um sistema de aquisição e condicionamento de sinais de EMG coletados no antebraço. Com redes neurais PMC e padrões de energia e entropia de componentes de decomposição *wavelet* foi possível detectar, com acurácia máxima de 82,7%, qual dedo era contraído. O circuito proposto tem apenas um canal de entrada com um par de eletrodos

e outro de referência. A amplificação foi feita com in-amp comercial e a filtragem com filtro ativo Chebyshev de quinta ordem.

A metodologia proposta foi testada com variação de parâmetros das técnicas. Utilizaram-se janelas temporais de 1024 e 2048 amostras e filtros *wavelet* Daubechies de comprimento 10 (db5) e 20 (db10), além de diversas topologias de PMC com uma a três camadas escondidas. Os melhores resultados em termos de acurácia e simplicidade do detector foi para rede com duas camadas escondidas contendo 25 e 20 neurônios, além de janela de 1024 amostras e filtro de comprimento 10. Porém, todas as configurações obtiveram acurácias entre 73% e 82.7%, exceto ao se utilizar somente uma camada escondida, sendo inferior a 70%.

Apesar dos resultados promissores, mais estudos devem ser realizados para se otimizar os parâmetros das técnicas. Pode-se analisar outras famílias e ordens de filtros *wavelet*, além de testar a transformada *wavelet packet*, a qual possui maior resolução tempo-frequência. Pode-se testar outros classificadores como máquinas de vetores de suporte. Como o movimento de alguns dedos interfere significativamente em outros, como mindinho e anelar, considera-se futuramente buscar outros atributos que diferenciem melhor os dedos. Também, a adição de mais um canal de EMG pode aumentar a acurácia da classificação.

Com respeito ao circuito, pode-se melhorar a relação sinal-ruído aproximando o circuito de condicionamento de sinais do ponto de fixação dos eletrodos e substituindo os eletrodos Ag/AgCl por eletrodos ativos. Além disso, pode-se usar um filtro de rejeição da interferência de 60 Hz da rede elétrica e uso de capacitores de desacoplamento de ruído nos pinos de alimentação dos circuitos integrados. Por fim, desenvolver um sistema de aquisição de sinais de custo reduzido para substituir a DAQ USB-6008.

AGRADECIMENTOS

Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e UTFPR.

REFERÊNCIAS

- Bansal, D. (2021). *Real-Time Data Acquisition in Human Physiology: real-time acquisition, processing, and interpretation - a MATLAB-based approach*. Academic Press, London, UK. doi:10.1016/C2019-0-04215-X.
- Bronzino, J.D. (2000). *The Biomedical Engineering Handbook*. CRC, Boca Raton, FL, 2 edition.
- Côté-Allard, U., Fall, C.L., Drouin, A., et al. (2019). Deep learning for electromyographic hand gesture signal classification using transfer learning. *IEEE Trans. Neural Syst. Rehab. Eng.*, 27(4), 760–771.
- Dimiz, P.S.R., da Silva, E.A.B., and Netto, S.L. (2014). *Processamento Digital de Sinais: Projeto e Análise de Sistemas*. Bookman, Porto Alegre.
- Dong, W., Yang, L., Gravina, R., and Fortino, G. (2022). Soft wrist-worn multi-functional sensor array for real-time hand gesture recognition. *IEEE Sensors J.*, (Early Access), 1–10. doi:10.1109/JSEN.2021.3050175.
- Duan, F., Dai, L., Chang, W., Chen, Z., Zhu, C., and Li, W. (2016). sEMG-based identification of hand motion commands using wavelet neural network combined with discrete wavelet transform. *IEEE Trans. Ind. Electron.*, 63(3), 1923–1934. doi:10.1109/TIE.2015.2497212.
- Enderle, J.D., Bronzino, J.D., and Blanchard, S.M. (2005). *Introduction to Biomedical Engineering*. Elsevier Academic Press, Amsterdam, The Netherlands.
- Englehart, K., Hudgins, B., and Parker, P.A. (2001). A wavelet-based continuous classification scheme for multifunction myoelectric control. *IEEE Trans. Biomed. Eng.*, 48(3), 302–311. doi:10.1109/10.914793.
- Fang, Y., Hettiarachchi, N., Zhou, D., and Liu, H. (2015). Multi-modal sensing techniques for interfacing hand prostheses: a review. *IEEE Sensors J.*, 15(11), 6065–6076. doi:10.1109/JSEN.2015.2450211.
- Guedes, A.C. (2021). Desenvolvimento de um sistema de aquisição e classificação contínua de padrões em sinais mioelétricos baseada em wavelets e redes neurais artificiais. Monografia (Engenharia Eletrônica), Universidade Tecnológica Federal do Paraná, Cornélio Procópio.
- Hudgins, B., Parker, P., and Scott, R.N. (1993). A new strategy for multifunction myoelectric control. *IEEE Trans. Biomed. Eng.*, 40(1), 82–94.
- Kumar, G., Yadav, S.S., Yogita, and Pal, V. (2022). Machine learning based framework to predict finger movement for prosthetic hand. *IEEE Sensors Lett.*, (Early Access), 1–4. doi:10.1109/LSENS.2022.3147518.
- Luu, D.K., Nguyen, A.T., Jiang, M., et al. (2022). Artificial intelligence enables real-time and intuitive control of prostheses via nerve interface. *IEEE Trans. Biomed. Eng.*, (Early Access). doi:10.1109/TBME.2022.3160618.
- Marchetti, P.H. and Duarte, M. (2011). Eletromiografia: uma breve revisão sobre os procedimentos de aquisição do sinal. *Terapia Manual*, 9, 548–553.
- Moleta, P. and Dobganski, J. (2007). Estudo da captação de sinais mioelétricos em instrumentação biomédica. In *An. Cong. Nac. Inic. Cient. (CONIC)*, 79–89.
- Okuno, R., Yoshida, M., and Akazawa, K. (2005). Compliant grasp in a myoelectric hand prosthesis: controlling flexion angle and compliance with electromyogram signals. *IEEE Eng. Med. Biol. Mag.*, 24(4), 48–56.
- Parker, P.A. and Scott, R.N. (1986). Myoelectric control of prostheses. *Crit. Rev. Biomed. Eng.*, 13(4), 283–310.
- Pfimer, F.W.D. (2009). Plataforma eletromecânica para simulação de entorse de tornozelo e medida de tempo de resposta muscular através de eletromiografia. Dissertação (Mestrado em Engenharia Elétrica), Universidade Estadual de Campinas, Campinas.
- Santos, R.A., Scalassara, P.R., and Endo, W. (2020). Classificação automática de patologias da laringe usando wavelets e sistemas inteligentes. In *An. XXIII Cong. Bras. Autom. (CBA)*, 1–7. doi:10.48011/asba.v2i1.1335.
- Silva, I.N., Spatti, D.H., and Flauzino, R.A. (2016). *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: fundamentos teóricos e aspectos práticos*. Artliber, São Paulo, 2a edition.
- Webster, J.G. (2009). *Medical Instrumentation: application and design*. John Wiley & Sons, Hoboken, NJ, USA.
- Xu, J., Mitra, S., Van Hoof, C., et al. (2017). Active electrodes for wearable EEG acquisition: review and electronics design methodology. *IEEE Rev. Biomed. Eng.*, 10, 187–198. doi:10.1109/RBME.2017.2656388.