

# Aquisição de Sinais de Eletromiografia com DSP e Classificação de Movimentos da Mão

Paulo R. Scalassara, Rafael Martinelli de Araujo, Pâmela de Souza Schiaber, Wagner Endo e Danilo H. Spatti

**Resumo**—A demanda por soluções em robótica assistiva tem aumentado nos últimos anos, principalmente com as crescentes aplicações de inteligência artificial. Assim, este estudo apresenta um classificador de três movimentos da mão: pinça com polegar e indicador, flexão de polegar e fechar a mão, usando características extraídas de sinais de eletromiografia de superfície nos domínios do tempo e da frequência. Avaliam-se os atributos individualmente e em conjunto usando sinais retirados de um banco de dados público e outros coletados com sensor *Myoware* e DSP F28379D. Obtiveram-se taxas de acerto da classificação entre 85% e 95%, tanto para modo offline quanto online.

**Palavras-Chave**—Eletromiografia, reconhecimento de padrões, DSP, sensor *Myoware*, redes neurais.

**Abstract**—The demand for assistive robotics solutions has been increasing in recent years, especially with the growing applications of artificial intelligence. Thus, this study presents a classifier for three hand movements: pinch with thumb and index finger, thumb flexion, and fist closure, using features extracted from surface electromyography signals in the time and frequency domains. The attributes are evaluated individually and in combination using signals taken from a public database and others collected with *Myoware* sensor and DSP F28379D. Classification accuracy rates between 85% and 95% were achieved, both in offline and online modes.

**Keywords**—Electromyography, pattern recognition, DSP, *Myoware* sensor, neural networks.

## I. INTRODUÇÃO

O desenvolvimento científico das últimas décadas possibilitou o uso efetivo de sinais biológicos em aplicações de reabilitação, em especial para próteses de membros superiores [1]. De acordo com o Sistema de Informações Hospitalares do Sistema Único de Saúde (SIHSUS), no Brasil, entre 2008 e 2015, tem-se registro de mais de 360 mil amputações de membros superiores e inferiores [2]. Esses procedimentos têm grande impacto na vida do paciente, tais como perda de mobilidade e auto-estima, além de prejuízos no ambiente de trabalho. Para a reabilitação desses pacientes, pode-se usar fisioterapia, tratamentos psicológicos e uso de próteses [3].

Nesse contexto, destacam-se as próteses inteligentes, que diferente das tradicionais, têm naturalidade e variedade de movimentos, melhorando a qualidade de vida. As próteses inteligentes utilizam sinais provenientes do corpo humano para realizar os movimentos [4]. Esses sinais podem ser provenientes de eletromiografia (EMG), ou seja, de natureza muscular [5], ou cerebral, por eletroencefalograma (EEG) [6].

P. R. Scalassara, R. M. Araujo, P. S. Schiaber e W. Endo, Universidade Tecnológica Federal do Paraná, Cornélio Procópio, PR, e-mail: [prscalassara,wendo]@utfpr.edu.br. D. H. Spatti, Universidade de São Paulo, São Carlos, SP, e-mail: spatti@icmc.usp.br.

Entretanto, os produtos disponíveis no mercado possuem alto custo e os dispositivos mais acessíveis muitas vezes não têm a devida certificação [7], especialmente no Brasil. Assim, são necessárias pesquisas que foquem no desenvolvimento de próteses desse tipo, em especial com o uso de medidas não invasivas, como a eletromiografia de superfície (sEMG). Nesse formato, os sinais elétricos são capturados por eletrodos posicionados na superfície da pele sobre o músculo de interesse. A sEMG possui aplicações além da classificação de movimentos, como avaliação de patologias, realização e acompanhamento de tratamentos e estudos de cinética corporal [8].

As principais técnicas de avaliação de sinais de EMG envolvem análises no domínio do tempo e da frequência, para eliminar ruídos e extrair características. Assim, a etapa de processamento de sinais é o ponto crucial no desenvolvimento de tecnologias assistivas com base em EMG [9].

Além dos métodos de reconhecimento de padrões, também são importantes as ferramentas para classificação dos padrões, responsáveis por receber as características do sinal e decidir qual o movimento a ser realizado. Atualmente, existem diversas técnicas, como máquina de vetores de suporte [5], discriminantes lineares [9], [10] e as redes neurais artificiais [11].

Em [12], classificaram-se movimentos das mãos usando atributos obtidos no domínio do tempo, como valor quadrático médio (RMS - *root mean square*), comprimento da forma de onda (WL - *waveform length*), número de cruzamentos por zero (ZC - *zero crossing*), mudança de sinal de inclinação (SSC - *slope sign change*) e valor absoluto médio (MAV - *mean absolute value*), e da frequência, como medidas de componentes da transformada *wavelet*, entre outras. Obtiveram taxas de acerto maiores do que 90% para classificação online.

De forma similar, em [13], realiza-se a classificação de movimentos da mão e do pulso com sinais coletados de oito eletrodos. Os atributos foram RMS, MAV, VAR (variância), momentos de 3<sup>a</sup>, 4<sup>a</sup> e 5<sup>a</sup> ordens, WL, ZC, SSC, entre outros. Usaram-se discriminantes lineares resultando em acurácia acima de 88% com diferentes combinações de atributos.

Por fim, em [14], obtém-se as seguintes características: VAR, RMS, valor retificado médio (ARV), SSC, ZC e WL. A classificação é realizada utilizando uma rede neural do tipo perceptron multicamadas (MLP - *multilayer perceptron*) e possui taxa de acerto médio de 87,5% para quatro movimentos da mão e do pulso com base em quatro eletrodos de superfície.

Seguindo uma abordagem semelhante, este estudo tem como objetivo apresentar um sistema online de identificação de movimentos da mão, realizando uma análise de diversos atributos obtidos dos sinais de sEMG nos domínios do tempo e da frequência. Inicialmente, fez-se uma avaliação prévia das

ferramentas utilizando um sistema offline composto por um banco de dados apresentado em [12]. Em seguida, para a etapa online, foram coletados sinais de forma similar para validação da metodologia, onde foi realizada a classificação online de movimentos da mão, usando-se redes neurais MLP otimizadas para maior acurácia com complexidade reduzida.

Após esta introdução, o texto está organizado em mais quatro seções. Na próxima, apresentam-se detalhes sobre o uso de sinais de EMG para detecção de movimentos, além do banco de dados utilizado e a aquisição dos sinais. Na Seção III, descreve-se a metodologia empregada no estudo, seguida pelos resultados e conclusões nas Seções IV e V respectivamente.

## II. SINAIS DE ELETROMIOGRAFIA

De forma simplificada, a eletromiografia é a análise da energia dos músculos e possui importante papel na medicina clínica [15]. O estudo da atividade elétrica na contração muscular se iniciou no final do século XIX, porém a técnica de sEMG em movimentos dinâmicos foi aperfeiçoada somente na década de 1940. A partir de então, essa ferramenta ganhou destaque nas mais diversas aplicações, conseguindo analisar até o comportamento das unidades motoras dos músculos [8].

As unidades motoras, que compõem os músculos, são caracterizadas por diversas fibras acionadas pelo sistema nervoso através de sinapses neuromusculares. Esse acionamento causa a criação de potenciais de ação nas unidades motoras, chamados de MUAPs (*motor unit action potential*), que são a base do estudo de EMG. Os MUAPs podem ser tratados como um sinal, ou conjunto de sinais, e representam o efeito das unidades motoras durante a contração do músculo.

### A. Aquisição dos Sinais

Do ponto de vista instrumental, para coleta do sinal de sEMG, usam-se circuitos de amplificação diferencial e rejeição de modo comum [16]. Para isso, tem-se três eletrodos: um de referência e dois de captação, os quais devem ser posicionados de forma paralela às fibras musculares. Essa configuração diminui interferências, inclusive a eletromagnética gerada pela rede elétrica, além de ter alta impedância de entrada, o que evita perdas de contato entre eletrodos e pele [8].

Neste estudo, usaram-se sinais de sEMG de um banco de dados público e também foram coletados sinais dos próprios autores. Os sinais do banco de dados público foram utilizados para treinamento e validação da rede sendo realizada uma classificação offline e os dados coletados foram utilizados na classificação online. Para realizar essa aquisição de dados, foi utilizado sistema *Myoware Muscle Sensor AT-04-001*, de fabricação da Advancer Technologies [17], Figura 1.

Esse sistema utiliza amplificação diferencial e rejeição comum, tendo ganho ajustável com valor máximo equivalente à tensão de alimentação (entre 3,1 e 5,9 V). Tem-se dois tipos de sinais analógicos de saída: bruto e processado (retificado e integrado) [17]. Atualmente, esse sensor tem sido muito usado em pesquisas e aplicações pessoais devido a seu custo reduzido em relação a sensores clínicos [18], [19], [20].

Em conjunto ao sistema *Myoware*, usou-se um módulo de extensão por cabos modelo *Myoware Cable Shield v.11* para




Fig. 1. Foto do sistema de aquisição de sinais de sEMG *Myoware Muscle Sensor AT-04-001* de fabricação da Advancer Technologies.

maior mobilidade. Os eletrodos adesivos utilizados foram do modelo 2223BRQ da 3M com contra pino de polímero recoberto com tratamento de Prata/Cloreto de Prata (Ag/AgCl). Para controlar a aquisição dos sinais e realizar o interfaceamento com computador, usou-se DSP LAUNCHPAD XL F28379D da Texas Instruments, Figura 2.




Fig. 2. Foto do DSP LAUNCHPAD XL F28379D da Texas Instruments.

### B. Banco de Dados

Além dos sinais coletados com *Myoware*, analisaram-se sinais disponibilizados por [12]. Esse banco de dados foi construído com ensaios coletados de 10 voluntários sem enfermidades neurológicas ou musculares, sentados com o braço apoiado em uma posição fixa. Considerando aplicação em prótese individual, utilizaram-se somente os sinais de um dos voluntários, escolhido aleatoriamente da base de dados.

A coleta dos sinais, conforme [12], foi realizada com sistema de aquisição da Delsys Inc., sendo os eletrodos diferenciais posicionados no antebraço, logo após o cotovelo, e eletrodo de referência no pulso. A conversão digital foi feita com conversor de 12 bits da National Instruments BNC-2090 com frequência de amostragem de 4 kHz.

O banco de dados possui dez classes de movimento, porém, aqui, foram usados somente três, Figura 3, respectivamente os movimentos de pinça, flexão do polegar e mão fechada. Os voluntários estavam em posição de relaxamento e mudaram para a posição indicada, mantendo por cinco segundos. Cada movimento foi repetido seis vezes com um período de descanso de cinco segundos entre as repetições.

Para a coleta realizada com *Myoware*, utilizou-se a mesma metodologia de [12], respeitando todos os requisitos de movimentos, tempo e repetições. Um eletrodo é fixado na região

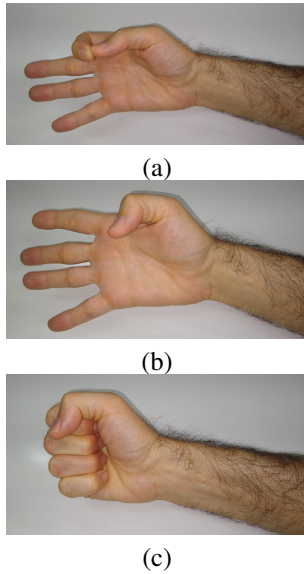


Fig. 3. Posições das mãos: (a) pinça, (b) polegar e (c) mão fechada.

posterior do antebraço, acima do músculo extensor dos dedos, outro eletrodo fixado na região anterior do antebraço, acima do músculo flexor superficial dos dedos, e o eletrodo de referência foi colocado no pulso. Usaram-se eletrodos adesivos e os pelos da região foram removidos antes da fixação.

Na próxima seção, apresenta-se a metodologia utilizada neste estudo, descrevendo a extração das características dos sinais de sEMG e o treinamento dos classificadores.

### III. METODOLOGIA

O sistema de detecção de movimentos da mão por sEMG consiste em três partes: aquisição e pré-processamento dos sinais, extração de características e classificação. Na primeira parte também é realizada a avaliação dos atributos dos sinais do banco de dados; na segunda, faz-se a validação da rede usando novos sinais coletados e, por fim, implementa-se um sistema de classificação em tempo real com base na rede validada. As três partes são apresentadas a seguir:

#### A. Aquisição e Pré-processamento dos Sinais

Os ensaios foram realizados com uma rede MLP com parâmetros otimizados, o que será explicado na próxima seção. A rede foi configurada com arquitetura *one of c-classes* de 0 a 1, funções de ativação tangente hiperbólica para as camadas escondidas e rampa linear para a camada de saída. Cada saída da rede era considerada ativada se seu valor fosse maior do que 0,8, não ativada se fosse menor do que 0,2, caso contrário, seria incerta, o que era considerado como erro nos testes. O conjunto de dados foi dividido em quatro repetições de movimentos para treinamento e dois para teste.

Os sinais foram coletados com frequência de amostragem de 2 kHz, o que é suficiente para capturar as informações mais relevantes do sEMG, que se concentram na faixa de frequências até 500 Hz [8]. Para retirar componentes irrelevantes de acima desse valor e abaixo de 20 Hz [12], projetou-se um filtro passa-faixa FIR *equiripple* com corte em 20 e 450 Hz.

Para treinamento e validação da MLP, os sinais de sEMG foram janelados com diferentes intervalos temporais. Com isso, é possível avaliar qual o tamanho ideal da janela para classificação eficiente. Busca-se o menor valor para se ter o menor custo computacional, porém com taxa de acerto adequada. Avaliaram-se janelas de 64, 128, 256, 512 e 1024 amostras com sobreposição de 50%, sendo realizados dez ensaios com cada valor. Comparou-se a acurácia média da classificação dos movimentos com os sinais de [12].

#### B. Extração de Características

A definição dos atributos é feita por meio da extração de características, analisando-se os sinais de sEMG no domínio do tempo e da frequência. Para essa última abordagem, usou-se a transformada *wavelet packet* (WPT) [21], a qual melhora a análise multiresolução da transformada *wavelet*.

A decomposição WPT é obtida com banco de filtros, resultando em uma estrutura em árvore com coeficientes de aproximação, por meio de filtros passa-baixas, e coeficientes de detalhes, por filtros passa-altas. Para continuar a decomposição nos ramos dos níveis abaixo, realiza-se o processo de subamostragem dos coeficientes antes da nova filtragem [22].

Os formatos dos filtros dependem da família *wavelet* utilizada. Existem diversas famílias, sendo algumas das mais populares Haar, Daubechies e Coiflets [22]. Conforme [23], a família Haar apresentou os melhores resultados em dados de sEMG, portanto foi a escolhida para esta pesquisa. Realizou-se três níveis de decomposição, resultando em oito componentes, sendo obtidos os seus valores de energia como atributos para classificação dos movimentos da mão. Ainda no domínio da frequência, extraiu-se a frequência mediana (MDF), dada pela frequência que divide a potência espectral em duas partes iguais, sendo muito usada em análises de sEMG [24].

A obtenção da decomposição WPT possui custo computacional geralmente maior do que as características extraídas dos sinais no domínio do tempo. Para tentar capturar as diferenças dos movimentos da mão, usaram-se os seguintes atributos no domínio do tempo: VAR, ZC, WL, SSC, RMS e ARV.

As características apresentadas foram obtidas dos sinais do banco de dados de [12]. Realizou-se a validação desses atributos para avaliar o comportamento dos classificadores e embasar os ensaios com os sinais coletados com *Myoware*. Dessa forma, essa etapa consiste em confirmar a eficácia do uso dos atributos extraídos.

Isso foi feito utilizando redes MLP sintonizadas com auxílio de otimização por enxame de partículas (PSO - *particle swarm optimization*) conforme metodologia apresentada em [23], que mostrou bons resultados. Otimizam-se os parâmetros de quantidade de camadas escondidas e neurônios por camada, além da taxa de aprendizado de treinamento, conforme Tabela I.

Inicialmente, realizou-se a análise do tamanho das janelas com 64, 128, 256, 512 e 1024 pontos. Para isso, os sinais de sEMG do banco de dados de [12] foram segmentados e fornecidos diretamente para uma rede MLP de duas camadas escondidas de sete e três neurônios respectivamente, taxa de aprendizado de 0,1 e 300 épocas de treinamento. Quanto maior a janela, menor a quantidade de amostras disponíveis para

TABELA I  
PARÂMETROS DA OTIMIZAÇÃO PSO DAS REDES MLP.

Parâmetro	Valor
Número de indivíduos da população	20
Número de iterações	15
Quantidade de camadas escondidas	1 a 3
Quantidade de neurônios por camada	0 a 15
Taxa de aprendizado	0,0025 a 0,5

o treinamento e validação da rede neural. Para se obter um valor médio de acertos, foram realizados dez ensaios para cada configuração.

### C. Classificação

Para a classificação online dos movimentos da mão, use-se a rede MLP otimizada pelo PSO na fase de validação. Essa rede foi implementada no DSP F28379D usando interface entre o ambiente de programação da Texas Instruments, chamado *Code Composer Studio*, e o Simulink/MATLAB, sendo possível converter o sistema projetado no MATLAB. Assim, todo o processamento é realizado no microcontrolador, desde a aquisição dos sinais, filtragem, extração de características e classificação, sem precisar de um computador.

Os filtros foram implementados transferindo os coeficientes projetados para o DSP. De forma similar, os pesos sinápticos da MLP treinada foram transferidos para o sistema, assim é possível embarcar e realizar a classificação online de forma muito similar ao projeto utilizando o banco de dados coletado.

Utilizou-se a saída de sinal retificado e integrado de um dos eletrodos do antebraço do *Myoware* como um gatilho para início da classificação dos movimentos da mão. Assim, quando o músculo está em relaxamento, o sistema não realiza classificação. Por fim, usaram-se três LEDs do DSP como indicadores do movimento detectado no classificador online.

A seguir, apresentam-se os resultados da MLP otimizada e da validação das características extraídas dos sinais de sEMG.

## IV. RESULTADOS

Em relação à classificação offline, as taxas de acurácia médias foram entre 87,8% e 100%, sendo as melhores taxas para janelas maiores. Para janelas de 512 e 1064 amostras, as taxas médias foram de 99,8% e 100%, visando menor custo computacional, decidiu-se usar 512 amostras nos próximos testes.

Em seguida, avaliou-se individualmente cada uma das características extraídas. Na Tabela II é possível observar as médias de acurácia utilizando os movimentos dos sinais de [12] e também dos sinais de aquisição.

Verificou-se que quatro dos atributos, VAR, AVR, RMS e WL, resultaram em taxa de erro de classificação próximo de 0% (acerto de 100%) com o banco de dados. Nota-se que esses atributos são obtidos dos sinais no domínio de tempo, sem a necessidade de os transformar para o domínio da frequência.

Usando os sinais da aquisição com *Myoware*, tem-se os resultados de acurácia de classificação na quarta e quinta colunas da Tabela II. Apesar de desempenho inferior ao

TABELA II  
ACURÁCIA DE CLASSIFICAÇÃO DOS ATRIBUTOS INDIVIDUALMENTE.

Atributo	Sinais do banco de dados		Sinais da aquisição	
	média	desvio	média	desvio
<b>MDF</b>	58,4	5,4	79,3	1,9
<b>WPT</b>	75,6	3,6	75,4	2,5
<b>VAR</b>	99,5	1,2	88,9	1,2
<b>ARV</b>	99,9	0,0	87,2	0,6
<b>RMS</b>	100,0	0,0	88,2	0,4
<b>SSC</b>	6,1	1,8	34,9	7,3
<b>WL</b>	100,0	0,0	86,6	1,9
<b>ZC</b>	20,7	3,6	62,5	1,9

TABELA III  
MATRIZ DE CONFUSÃO DA REDE OTIMIZADA.

Esperado	Obtido			Incerteza
	Pinça	Polegar	Mão Fechada	
<b>Pinça</b>	85,5	10,5	5,3	0,0
<b>Polegar</b>	0,0	93,4	0,0	5,3
<b>Mão Fechada</b>	1,3	3,9	94,7	0,0

anterior, os mesmos quatro atributos foram os que tiveram as menores taxas de erro, entre 11% e 14%. Assim, fez-se ensaios combinando esses quatro atributos nos três movimentos, primeiramente com os dois atributos que tiveram menores erros, RMS e VAR; depois, adicionando AVR e, por fim, também WL. A acurácia média, após dez ensaios de cada movimento, foi 88,9%, 88,4% e 89,1% respectivamente, com desvios padrão entre 1% e 2,5%, portanto sem diferença relevante entre eles. Apesar disso, para maior robustez do classificador, optou-se por usar os quatro atributos.

Com o tamanho da janela escolhido e após a seleção das características extraídas dos sinais que serão fornecidas para o classificador, utilizou-se a otimização por PSO para encontrar a melhor arquitetura da rede MLP. Após esse processo, o maior valor de acurácia foi 91,35%, melhor que os resultados anteriores. Essa rede usa arquitetura com duas camadas escondidas de 9 e 7 neurônios respectivamente e foi treinada com taxa de aprendizado de 0,39. A matriz de confusão da classificação da rede otimizada para os dados coletados com *Myoware* é apresentada na Tabela III. Não há confusão do classificador entre os movimentos para o polegar, porém há incerteza de 5,3. Para os outros dois movimentos há um leve erro nas classificações, mas os erros são pequenos.

Por fim, após os testes com sinais do banco de dados e coletados com o *Myoware*, fez-se a classificação online com a rede MLP otimizada. Para acompanhamento, usaram-se os LEDs do DSP e também a comunicação com Simulink. Os resultados foram compatíveis com aqueles obtidos para os sinais processados de forma offline. Observou-se taxa de acertos de aproximadamente 93%, 100% e 95% para os movimentos de pinça, polegar e mão fechada respectivamente. A Figura 4 ilustra o comportamento do sistema com um ensaio com movimentos de polegar, mão fechada e pinça sequencialmente, indicando, em (a), o sinal de um eletrodo, e em (b) os sinais de acionamento dos LEDs do DSP indicativos dos movimentos.

Analisando-se esse resultado, percebe-se, na transição dos movimentos, uma breve instabilidade, entretanto estabiliza após a posição ser mantida constante por alguns segundos.



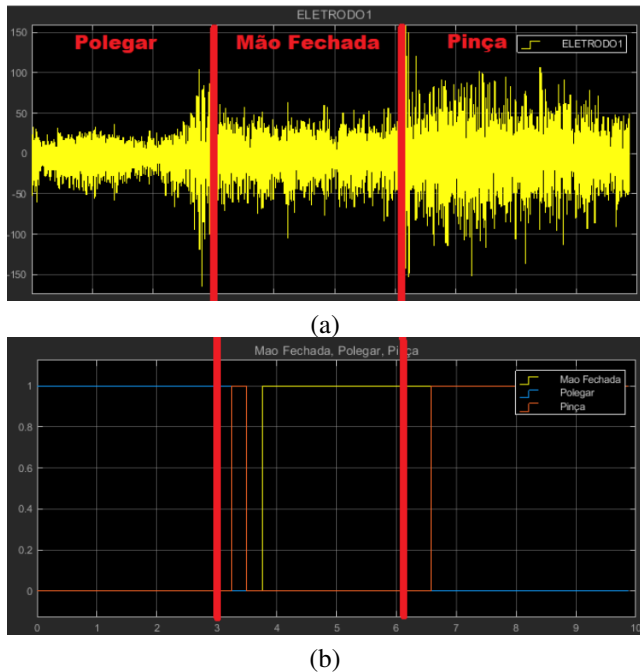


Fig. 4. Sinais de ensaio com sequência de movimentos: polegar, mão fechada e pinça. (a) sinal de um eletrodo, (b) sinais de acionamento dos LEDs.

## V. CONCLUSÕES

Este artigo apresentou um sistema de classificação dos movimentos da mão: pinça, polegar e mão fechada, com foco em futuras aplicações em próteses inteligentes e aplicações clínicas, como patologias musculares. Realizaram-se ensaios de desempenho com os parâmetros das técnicas de processamento, como tamanho de janelamento e as características extraídas dos sinais de sEMG.

A maior eficiência de classificação foi obtida com janelas de 512 pontos (256 ms) e usando os atributos RMS, ARV, WL e VAR, obtidos dos sinais no domínio do tempo. Os atributos extraídos dos sinais no domínio da frequência não apresentaram resultados de classificação comparáveis aos temporais.

Para o treinamento das MLPs, usou-se otimização por PSO para os números de camadas escondidas e neurônios, focando em obter uma rede adequada para a aplicação. Para essa rede otimizada, as taxas médias de acurácia foram entre 85% e 95% para detecção dos movimentos de mão propostos. Além disso, avaliou-se a eficiência do sistema de classificação em dois cenários: offline, usando o banco de dados disponibilizado por [12] e construído usando sensor *Myoware*, além de classificação online com sistema composto pelo DSP F28379D. O sistema online obteve resultados similares ao offline e, em movimentos prolongados, alguns resultados superiores.

Portanto, uma das principais contribuições deste estudo foi apresentar avaliações de desempenho da classificação usando diversos atributos extraídos dos sinais de sEMG nos domínios do tempo e da frequência, individualmente e em conjunto. Também, demonstrar o desenvolvimento de um sistema embarcado para classificação online com a metodologia proposta.

Por fim, para pesquisas futuras, objetiva-se avaliar outros movimentos da mão e quais atributos capturam as assinaturas

dos movimentos nos sinais de sEMG, além de projetar um sistema embarcado próximo de aplicações em robótica assistiva.

## AGRADECIMENTOS

Os autores agradecem à UTFPR e à USP. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

## REFERÊNCIAS

- [1] C. Ahmadzadeh, M. Khoshnam, and C. Menon, "Human machine interfaces in upper-limb prosthesis control: A survey of techniques for preprocessing and processing of biosignals," *IEEE Signal Processing Mag.*, vol. 38, no. 4, pp. 12–22, 2021.
- [2] A. M. Peixoto *et al.*, "Prevalência de amputações de membros superiores e inferiores no estado de alagoas atendidos pelo sus entre 2008 e 2015," *Fisioter. Pesqui.*, vol. 24, no. 4, pp. 378–384, 2017.
- [3] S. Agarwal *et al.*, *Sarcoma - A Multidisciplinary Approach to Treatment*, ch. Rehabilitation for Patients with Bone and Soft Tissue Sarcoma. Springer, 2017.
- [4] Y. Sato *et al.*, "Body ownership and agency altered by an electromyographically controlled robotic arm," *R. Soc. Open Sci.*, vol. 5, no. 5, p. 172170, 2018.
- [5] C. Tepe and M. C. Demir, "Real-time classification of emg myo armband data using support vector machine," *IRBM*, vol. 43, pp. 300–308, 2022.
- [6] J. Meng *et al.*, "Noninvasive electroencephalogram based control of a robotic arm for reach and grasp tasks," *Sci. Rep.*, vol. 6, p. 38565, 2016.
- [7] S. Heywood *et al.*, "Low-cost electromyography - validation against a commercial system using both manual and automated activation timing thresholds," *J. Electromyogr. Kinesiol.*, vol. 42, pp. 74–80, 2018.
- [8] E. Criswell, *Cram's Introduction to Surface Electromyography*. Jones & Bartlett Learning, 2nd ed., 2010.
- [9] Y. A. Jarrah *et al.*, "High-density surface emg signal quality enhancement via optimized filtering technique for amputees' motion intent characterization towards intuitive prostheses control," *Biomed. Signal Process. Control*, vol. 74, p. 103497, 2022.
- [10] N. Jarrassé *et al.*, "Classification of phantom finger, hand, wrist, and elbow voluntary gestures in transhumeral amputees with semg," *IEEE Trans. Neural Syst. Rehab. Eng.*, vol. 25, no. 1, pp. 71–80, 2017.
- [11] T. Mahboob, M. Y. Chung, and K. W. Choi, "Emg-based 3d hand gesture prediction using transformer-encoder classification," *ICT Express*, vol. (no prelo), 2023.
- [12] R. N. Khushaba *et al.*, "Combined influence of forearm orientation and muscular contraction on emg pattern recognition," *Expert Syst. Appl.*, vol. 61, pp. 154–161, 2016.
- [13] S. Negi, Y. Kumar, and V. M. Mishra, "Feature extraction and classification for emg signals using linear discriminant analysis," in *Int. Conf. Advan. Comp. Comm. Automation*, pp. 1–6, 2016.
- [14] J. N. Mello, E. F. Schmiele, and A. B. Soares, "Metodologia para classificação de movimentos da mão baseada em padrões eletromiográficos," in *Cong. Bras. Eletromiogr. Cinesiol.*, pp. 645–648, 2018.
- [15] B. Katirji, *Electromyography in Clinical Practice - A Case Study Approach*. Oxford University Press, 3rd ed., 2018.
- [16] C. J. De Luca, "Surface electromyography: Detection and recording," *DelSys Inc.*, vol. 10, no. 2, pp. 1–10, 2002.
- [17] Advancer Technologies, *MyoWare Muscle Sensor (AT-04-001): Muscle Electromyography Sensor for Microcontroller Applications*, 2015.
- [18] J. Gotuzzo *et al.*, "Electromyography based orthotic arm and finger rehabilitation system," in *IEEE Int. Conf. Healthcare Info.*, pp. 338–339, 2018.
- [19] N. Foley and C.-H. Yu, "Muscare+: Muscle monitoring for anomalies," in *IEEE World AI IoT Cong.*, pp. 425–430, 2022.
- [20] S. Chun, S. Kim, and J. Kim, "Human arm workout classification by arm sleeve device based on machine learning algorithms," *Sensors*, vol. 23, no. 6, p. 3106, 2023.
- [21] R. Coifman *et al.*, *Signal processing and compression with wavelet packets*, pp. 363–379. Dordrecht: Springer Netherlands, 1994.
- [22] S. Mallat, *A Wavelet Tour of Signal Processing - The Sparse Way*. Boston: Academic Press, 3rd ed., 2009.
- [23] A. Lima *et al.*, "Optimized artificial neural network for biosignals classification using genetic algorithm," *Int. J. Control Autom. Syst.*, vol. 30, p. 371–379, 2019.
- [24] M. Bigliassi *et al.*, "Fourier and wavelet spectral analysis of emg signals in 1-km cycling time-trial," *Appl. Math.*, vol. 5, pp. 1878–1886, 2014.