

Sistema de Prótese de Mão de Baixo Custo Controlado por Sinais Mioelétricos

Maria Eduarda Saraiva Pinheiro¹, Erika Alves¹, Helton Maia^{*1}

¹Universidade Federal do Rio Grande do Norte, Natal, Brasil (helton.maia@ufrn.br)

Resumo: Este trabalho propõe o desenvolvimento de uma prótese de mão de baixo custo, utilizando sinais eletromiográficos (EMG) e uma Raspberry Pi Pico W. Os sinais elétricos gerados pela contração muscular do antebraço são captados por sensores EMG e traduzidos em comandos para controlar os movimentos da prótese. A Raspberry Pi Pico realiza o processamento dos dados por meio de uma rede neural artificial, identificando o movimento a ser executado. O uso da impressão 3D na confecção da prótese torna o projeto acessível e permite sua personalização conforme as necessidades do usuário.

Palavras-chave: Prótese; Eletromiografia; Raspberry; Impressão 3D; Acessibilidade.

INTRODUÇÃO

Os sinais eletromiográficos (EMG) representam a atividade elétrica gerada pelas fibras musculares durante a contração. A partir da utilização de sensores específicos, é possível coletar esses sinais provenientes de diferentes unidades motoras. Em aplicações protéticas, os sinais EMG geralmente são adquiridos por meio de eletrodos posicionados na superfície da pele, variando de acordo com o nível de amputação e o tipo de informação desejada (RAEZ, 2006).

Nos últimos anos, avanços significativos têm sido alcançados no uso desses sinais em sistemas de controle de próteses, uma vez que a análise das características extraídas dos sinais permite interpretações confiáveis dos movimentos pretendidos (GEETHANJALI, 2016).

Segundo dados da Pesquisa Nacional de Saúde (PNS), realizada em 2019, aproximadamente 2,7% da população brasileira com dois anos ou mais de idade, o que corresponde a cerca de 5,5 milhões de pessoas, apresenta deficiência física relacionada ao uso dos membros superiores (IBGE, 2021). Esse cenário evidencia a necessidade de soluções acessíveis que possibilitem maior independência e inclusão social para esse público.

Ainda conforme dados da Pesquisa Nacional por Amostra de Domicílios (PNAD), pessoas com deficiência estão menos inseridas no mercado de trabalho e nas instituições de ensino, o que impacta diretamente seu acesso à renda (BRASIL, 2023). O desenvolvimento de próteses funcionais e de baixo

custo pode contribuir de forma significativa para sua inclusão social e econômica.

Um estudo realizado por Yamamoto et al. (2019) mostrou que, entre pessoas com amputação de membro superior, aquelas que utilizavam próteses, especialmente as mioelétricas, apresentavam taxas mais elevadas de emprego em tempo integral. Em contrapartida, a maioria dos que não usavam prótese estava desempregada ou aposentada, o que evidencia o impacto positivo desse tipo de tecnologia.

Neste trabalho, propõe-se o desenvolvimento de uma prótese de mão acessível, confeccionada com impressão 3D e controlada por sinais EMG captados por três eletrodos de superfície. Dois desses eletrodos são posicionados no antebraço e um próximo ao cotovelo, atuando como eletrodo de referência. Os sinais são processados por uma Raspberry Pi Pico W, que utiliza uma rede neural para classificar os movimentos de abertura ou fechamento da mão, permitindo seu controle em tempo real. Essa abordagem busca oferecer uma solução de baixo custo, personalizável e de fácil acesso.

MATERIAL E MÉTODOS

As etapas do trabalho estão resumidas na Figura 1, que apresenta um diagrama de fluxo com todos os processos realizados no desenvolvimento do sistema.

Para a aquisição dos sinais eletromiográficos (EMG), foi utilizado o sensor EMG v3 da Advancer Technologies, desenvolvido para operar diretamente com microcontroladores, emitindo um sinal amplificado e suavizado. As informações sobre o sensor foram obtidas na página oficial do fabricante

no repositório GitHub (ADVANCER TECHNOLOGIES, 2014).

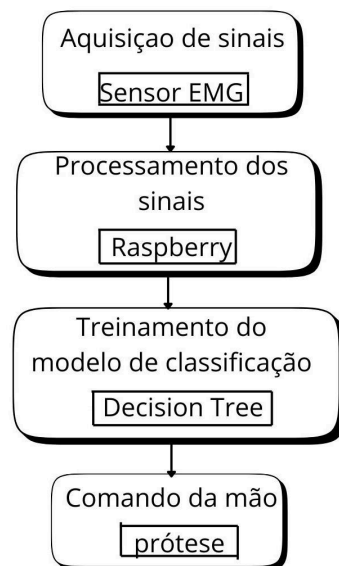


Figura 1. Diagrama de fluxo que representa as etapas realizadas para o desenvolvimento do sistema.

A plataforma de processamento escolhida foi a Raspberry Pi Pico W, uma alternativa acessível e eficaz para aplicações embarcadas (KLOPF e CONSTANTINO, 2022). A leitura dos sinais analógicos é realizada por meio do pino ADC da placa, que converte a tensão em valores digitais. O sensor EMG é alimentado por duas baterias de 9 volts conectadas em série. Já a Raspberry Pi Pico W é conectada via cabo USB a um notebook, em vez de estar ligada diretamente à rede elétrica. Essa escolha visa reduzir interferências eletromagnéticas provenientes da alimentação de corrente alternada, que poderiam comprometer a qualidade do sinal. A configuração completa pode ser visualizada na Figura 2.




Figura 2. Representação do sistema para aquisição e processamento dos sinais.

Além disso, o software utilizado para a execução do código de aquisição dos dados foi a IDE Thonny, com a linguagem de programação MicroPython. No script, foram definidos o pino GPIO de entrada da Raspberry Pi, o nome do arquivo de saída, a taxa de amostragem e os tempos de exibição da mensagem que orienta o usuário quanto ao movimento a ser realizado.

A taxa de amostragem adotada foi de 500 Hz, valor considerado suficiente para capturar sinais eletromiográficos com fidelidade, permitindo a distinção entre diferentes movimentos musculares sem comprometer a coerência na classificação (LI et al., 2011).

Durante a aquisição, foram capturados apenas movimentos de abertura e fechamento da mão, sincronizados com mensagens exibidas na tela, que indicavam quando realizar cada movimento. A duração total da coleta foi de 30 segundos, com alternância dos movimentos a cada 5 segundos, iniciando com a mão aberta no primeiro intervalo.

Ao final da aquisição, o código gera automaticamente um arquivo CSV (*Comma-Separated Values*) contendo os valores digitais capturados e seus respectivos registros temporais. Foram realizadas 10 repetições idênticas dessa coleta, com o objetivo de verificar a consistência dos sinais captados e fornecer uma quantidade adequada de dados para o treinamento do modelo de classificação, o que contribui para uma melhor acurácia do sistema.

Após a coleta dos dados, foi realizada uma etapa de filtragem do sinal bruto. Utilizou-se um filtro passa-banda de 20 a 250 Hz e um filtro *notch* de 60 Hz, com o intuito de eliminar ruídos da rede elétrica e artefatos de baixa e alta frequência. A faixa de 20 a 250 Hz compreende os principais componentes do sinal EMG, enquanto a filtragem abaixo de 20 Hz reduz artefatos de movimento, e a filtragem acima de 250 Hz remove ruídos de alta frequência (LEONE et al., 2025).

A Figura 3 apresenta o espectrograma do sinal filtrado, permitindo visualizar a distribuição da potência em diferentes faixas de frequência ao longo do tempo. É possível observar um aumento na magnitude da potência nas regiões que correspondem à contração muscular, o que confirma a coerência dos sinais EMG captados pelo sensor.




Figura 3. Espectrograma do sinal EMG mostrando os valores da potência espectral ao longo do tempo.

Posteriormente, foram extraídas as características do sinal de cada amostra, que foram salvas em um novo arquivo CSV, como RMS (*Root Mean Square*), média, desvio padrão, *waveform length* e o rótulo, para indicar se a mão estava aberta ou fechada. Pois, essa extração representa um objeto a partir de medidas que possuem valores semelhantes entre objetos da mesma classe e valores diferentes para objetos de classes diferentes, sendo possível realizar a detecção do movimento nesse caso (MOKHLESBADIFARAHANI e GUNAN, 2015). Assim, foram utilizadas algumas das principais características do sinal, como será mostrado nas equações abaixo, em que x representa o valor do sinal EMG, k é o número de cada amostra e N é o número total de amostras.

A Equação 1 mostra a média absoluta dos valores do sinal, que representa a área sob a curva do sinal e assim é possível observar o nível de ativação muscular médio. A Equação 2 mostra o desvio padrão do sinal, que mede a variação do sinal. A Equação 3 mostra a *waveform length*, que representa a complexidade, especificando a amplitude, frequência e duração da onda (KHAIRUDDIN et al., 2021).

$$MAV = \frac{1}{N} \sum_{k=1}^N |x_k| \quad (1)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{k=1}^N (x_k - \bar{x})^2} \quad (2)$$

$$WL = \sum_{k=1}^{N-1} |x_{k+1} - x_k| \quad (3)$$

Após a extração das características, foi adicionada uma coluna com os valores dos rótulos, ou seja, como no código estava especificado o momento em

que a mão estava aberta ou fechada, foi possível utilizar uma estrutura condicional, que a partir dos intervalos de tempo, classificava a mão. Sendo rotulada como 0 para aberta e 1 para fechada, pois valores numéricos facilitam o processo durante o treinamento do modelo.

Posteriormente, esses arquivos gerados com as características do sinal foram unidos em uma lista. E a partir desses dados foi possível treinar um modelo e fazer a classificação utilizando o classificador *Decision Tree*, que foi escolhido devido a sua simplicidade e fácil conversão para implementar no sistema embarcado (KRISHNAKUMAR e OGRAS, 2021), obtendo-se 85% de acurácia. Posteriormente, o modelo foi convertido para uma estrutura condicional, compatível com o microcontrolador, pois a sua implementação direta possui um elevado consumo de memória (SAHA et al., 2022) e além disso, a biblioteca utilizada no treinamento do modelo não possui compatibilidade com a linguagem de programação utilizada na Raspberry Pi Pico, que é o micro Python. E desse modo, foi possível a detecção dos estados da mão, se está aberta ou fechada, utilizando os eletrodos de superfície e a Raspberry Pi Pico.

De acordo com a documentação da biblioteca Scikit-learn, o *Decision Tree* é um método de aprendizado de máquina supervisionado que aprende os padrões a partir dos dados que foram implementados na entrada e desse modo cria regras de decisão do tipo “se-então-senão”, para representar os padrões de forma simples. Assim, em cada nó da árvore é feita uma decisão binária, como representado na Figura 4, em que há uma separação entre os dados da esquerda e da direita que atendem a uma determinada condição até que atinja um nó “puro”, ou seja, com apenas uma classe e faça a previsão da classe (CHEN et al., 2022). Esse, apesar de ser um sistema de classificação simples, se mostrou um método eficaz para a detecção do movimento da mão, uma vez que possui apenas duas classes.




Figura 4. Representação do modelo de classificação *Decision Tree*

Na figura 5 é possível observar a configuração geral do funcionamento do sistema durante a aquisição dos dados, que é o mesmo da detecção do movimento da mão, e inclui a Raspberry Pi Pico W, o sensor emg v3, as duas pilhas de 9 volts e o notebook com o software da IDE Thonny.




Figura 5. Configuração geral do sistema de captura de dados.

Os modelos matemáticos do sinal EMG são muito importantes para o melhor entendimento dos processos fisiológicos envolvidos e além disso na avaliação de variáveis técnicas que podem influenciar o registro dos sinais. Assim, a equação 4, mostra a taxa de disparo de uma unidade motora de acordo com o modelo proposto por Petersen e Rostalski (2019), em que o CD (*common drive*) é o nível de impulso comum ao músculo, o CD_{rec} é o limiar de recrutamento da unidade motora *i*, e o C_j, *j*=1 a *j*=5 são os parâmetros ajustados para cada músculo.

$$\lambda(CD(t); CD_{rec(i)}) = C4 \cdot CD(t) + (C3 - C1e^{-CD(t)/C2}) \cdot CD_{rec(i)} + C5 \quad (4)$$

RESULTADOS E DISCUSSÃO

A implementação da Raspberry Pico Pi e do sensor emg demonstraram uma boa eficiência e capacidade de respostas relativamente rápidas, conseguindo capturar os sinais musculares de maneira eficiente durante a aquisição de dados e uma detecção dos movimentos da mão que, segundo a acurácia do modelo apresenta 85% de taxa de acerto. Porém, o sistema utilizado ainda possui algumas limitações, como o fato do sensor ser de superfície e sofrer interferência de grupos musculares próximos, além da interferência dos sinais que são emitidos por aparelhos elétricos próximos, e possui também a influência do suor e resistência da pele. Além disso, a utilização de apenas dois gestos da mão simplifica a classificação, mas limita a funcionalidade do sistema da prótese. E também a utilização do classificador

Decision Tree, que se mostra eficiente para movimentos simples, pode ser menos preciso para problemas mais complexos com a implementação de outros gestos. Além disso, esse trabalho também é composto ainda por uma estrutura física de uma prótese de mão, desenvolvida por uma impressora 3D, porém ainda não foi possível realizar essa etapa, sendo prevista para trabalhos futuros.

As Figuras 6 e 7 mostram os gestos de abertura e fechamento da mão que estão sendo detectados pelo classificador em tempo real.



Figura 6. Detecção da mão fechada pelo modelo.





Figura 7. Detecção da mão aberta pelo modelo.

Porém, mesmo com toda disponibilidade tecnológica de recursos atualmente, a confecção de uma prótese de mão de baixo custo que utiliza sinais EMG ainda são um desafio, pois os movimentos realizados pela mão humana são muito complexos e isso requer a utilização de um reconhecimento de padrões que necessita de um recurso computacional muito avançado e consequentemente a utilização de um sistema embarcado com maior capacidade de processamento, o que torna o produto final mais caro; além disso, é preciso a integração dos componentes utilizados para que eles sejam executados em tempo



real, possuam um tempo de resposta relativamente rápido e que interajam de forma coerente para se ter um controle adequado do movimento (PARAJULI et al., 2019). Desse modo, precisamos continuar cada vez mais buscar soluções que possam ser incorporadas a esse sistema e desenvolver tecnologias para melhorar a sua eficiência.

CONCLUSÃO

Essa pesquisa consiste no desenvolvimento de uma prótese robótica de mão acessível controlada por sinais eletromiográficos, utilizando um sensor eletromiográfico (EMG) de superfície, uma Raspberry Pi Pico W e a tecnologia de impressão 3D para a produção da estrutura física da prótese. Com a aquisição dos dados eletromiográficos pelo sensor e posteriormente o processamento desses sinais e extração de suas características foi possível treinar um modelo de classificação utilizando o *Decision Tree*, que é capaz de detectar o movimento que está sendo executado pela mão, com os eletrodos no antebraço. Sendo que neste estudo foram utilizados apenas o movimento de abertura e fechamento da mão. E a estrutura física da prótese 3D ainda não foi feita nessa etapa do trabalho, sendo assim será realizada futuramente. Desse modo, essa abordagem inclui além de uma solução mais acessível, a inclusão de pessoas que não possuem esse membro para que elas possam realizar atividades básicas.

AGRADECIMENTOS

Agradecemos a Universidade Federal do Rio Grande do Norte (UFRN), a Escola de Ciência e Tecnologia (ECT) e ao Laboratório de Robótica e Automação (LAR) pelo suporte essencial nessa pesquisa.

REFERÊNCIAS

ADVANCER TECHNOLOGIES. *Muscle Sensor v3 Users Manual: Three-lead Differential Muscle/Electromyography Sensor for Microcontroller Applications*. 4 fevereiro 2013. 409 p. Disponível em: <https://github.com/AdvancerTechnologies/MuscleSensorV3/blob/master/Documents/Muscle%20Sensor%20v3%20Users%20Manual.pdf>. Acesso em: 15 jun. 2025.

Anish Krishnakumar and Umit Y. Ogras. 2021. Performance analysis and optimization of decision tree classifiers on embedded devices: work-in-progress. In Proceedings of the 2021 International Conference on Embedded Software (EMSOFT '21). Association for Computing Machinery, New York, NY, USA, 37–38. <https://doi.org/10.1145/3477244.3477618>

BRASIL. Ministério dos Direitos Humanos e da Cidadania. *Brasil tem 18,6 milhões de pessoas com deficiência, indica pesquisa divulgada pelo IBGE e MDHC*. Brasília, 7 jul. 2023. Disponível em: <https://www.gov.br/mdh/pt-br/assuntos/noticias/2023/julho/brasil-tem-18-6-milhoes-de-pessoas-com-deficiencia-indica-pesquisa-divulgada-pelo-ibge-e-mdhc>. Acesso em: 14 jun. 2025.

CHEN, Kuan-Hsun et al. Realização eficiente de árvores de decisão para inferência em tempo real. *ACM Transactions on Embedded Computing Systems*, v. 21, n. 6, art. 68, p. 1–26, nov. 2022. doi:10.1145/3508019.


Geethanjali P., Myoelectric control of prosthetic hands: state-of-the-art review. *Med Devices (Auckl)*. 2016 Jul 27;9:247-55. doi: 10.2147/MDER.S91102. PMID: 27555799; PMCID: PMC4968852.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. PNS 2019: país tem 17,3 milhões de pessoas com algum tipo de deficiência. *Agência de Notícias*, 26 ago. 2021. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-sala-de-imprensa/2013-agencia-de-noticias/releases/31445-pns-2019-pais-tem-17-3-milhoes-de-pessoas-com-algu-m-tipo-de-deficiencia>. Acesso em: 13 jun. 2025.

Klopf, E., & Costantino, MT (abril de 2022), *Avaliação do uso do MicroPython e do Raspberry Pi Pico em atividades laboratoriais para turmas de graduação em Engenharia Eletromagnética*. Artigo apresentado na Conferência da Seção do Atlântico Médio da ASEE de Primavera de 2022, Newark, Nova Jersey. 10.18260/1-2--40051

Leone, A.; Carluccio, AM; Caroppo, A.; Manni, A.; Rescio, G. Uma revisão sistemática da eletromiografia de superfície na sarcopenia: músculos envolvidos, técnicas de processamento de sinais, características significativas e abordagens de inteligência artificial. *Sensors* 2025, 25, 2122. <https://doi.org/10.3390/s25072122>

Li, G., Li, Y., Yu, L. et al. Problemas de Condicionamento e Amostragem de Sinais EMG no Reconhecimento de Movimento de Próteses Mioelétricas Multifuncionais. *Ann Biomed Eng* 39, 1779–1787 (2011). <https://doi.org/10.1007/s10439-011-0265-x>



Mohd Khairuddin I, Sidek SN, P P Abdul Majeed A, Mohd Razman MA, Ahmad Puzi A, Md Yusof H. The classification of movement intention through machine learning models: the identification of significant time-domain EMG features. *PeerJ Comput Sci.* 2021 Feb 25;7:e379. doi: 10.7717/peerj-cs.379. PMID: 33817026; PMCID: PMC7959624.

MOKHLESABADIFARAHANI, B.; GUNJAN, V. K. Introduction to EMG Technique and Feature Extraction. In: MOKHLESABADIFARAHANI, B.; GUNJAN, V. K. *EMG Signals Characterization in Three States of Contraction by Fuzzy Network and Feature Extraction*. Singapore: Springer, 2015. p. 14–15. DOI: 10.1007/978-981-287-320-0_1.

Parajuli N, Sreenivasan N, Bifulco P, Cesarelli M, Savino S, Niola V, Esposito D, Hamilton TJ, Naik GR, Gunawardana U, Gargiulo GD. Real-Time EMG Based Pattern Recognition Control for Hand Prostheses: A Review on Existing Methods, Challenges and Future Implementation. *Sensors (Basel).* 2019 Oct 22;19(20):4596. doi: 10.3390/s19204596. PMID: 31652616; PMCID: PMC6832440.

Petersen E, Rostalski P. A Comprehensive Mathematical Model of Motor Unit Pool Organization, Surface Electromyography, and Force Generation. *Front Physiol.* 2019 Mar 8;10:176. doi: 10.3389/fphys.2019.00176. PMID: 30906263; PMCID: PMC6418040.

Raez MB, Hussain MS, Mohd-Yasin F. Techniques of EMG signal analysis: detection, processing, classification and applications. *Biol Proced Online.* 2006;8:11-35. doi: 10.1251/bpo115. Epub 2006 Mar 23. Erratum in: *Biol Proced Online.* 2006;8:163. doi: 10.1251/bpo124. PMID: 16799694; PMCID: PMC1455479.

Saha SS, Sandha SS, Srivastava M. Machine Learning for Microcontroller-Class Hardware: A Review. *IEEE Sens J.* 2022 Nov 15;22(22):21362-21390. doi: 10.1109/jsen.2022.3210773. Epub 2022 Oct 5. PMID: 36439060; PMCID: PMC9683383.

SCIKIT-LEARN. *Tree - Decision Trees*. Disponível em: <https://scikit-learn.org/stable/modules/tree.html>. Acesso em: 15 jun. 2025.

Yamamoto M, Chung KC, Sterbenz J, Shauver MJ, Tanaka H, Nakamura T, Oba J, Chin T, Hirata H. Cross-sectional International Multicenter Study on Quality of Life and Reasons for Abandonment of Upper Limb Prostheses. *Plast Reconstr Surg Glob Open.* 2019 May 24;7(5):e2205. doi: 10.1097/GOX.0000000000002205. PMID: 31333938; PMCID: PMC6571339.