

DESENVOLVIMENTO DE UM SISTEMA DE CLASSIFICAÇÃO DE MOVIMENTOS DA MÃO BASEADO EM SINAIS EMG UTILIZANDO APRENDIZADO DE MÁQUINA

DEVELOPMENT OF A HAND MOVEMENT CLASSIFICATION SYSTEM BASED ON EMG SIGNALS USING MACHINE LEARNING

**Kalleby Evangelho Mota¹, Andrisa dos Santos Silva², Marcos Vinicius Pasqualoto Prior³,
Mirkos Ortiz Martins⁴ e Luis Fernando Rodrigues Jr⁵**

RESUMO

Pessoas com amputações de membros superiores enfrentam desafios significativos para realizar atividades cotidianas, como pegar objetos ou manipular ferramentas, o que impacta diretamente sua qualidade de vida. As próteses mioelétricas oferecem uma solução ao restaurar parte da função motora perdida. No entanto, controlar essas próteses com precisão ainda é desafiador devido à complexidade dos sinais eletromiográficos (EMG) e à variabilidade entre os usuários. Este trabalho desenvolve um sistema de classificação de movimentos da mão, focado em próteses de baixo custo, utilizando sinais EMG e algoritmos de aprendizado de máquina. O sistema coleta sinais EMG por meio do eHealth Sensor Platform V2.0, com eletrodos posicionados no antebraço para garantir a captação adequada. Após o pré-processamento, que inclui a aplicação de filtros para remoção de ruídos, são extraídas características como MAV, RMS, ZC e SSC, que capturam informações cruciais sobre a amplitude e variação dos sinais. Utiliza-se um classificador Random Forest para identificar os movimentos de mão aberta e fechada, atingindo 92,19% de precisão em testes realizados. Embora o sistema ainda não tenha sido integrado a uma prótese, os próximos passos incluem a expansão da base de dados e a futura implementação em uma prótese mioelétrica de baixo custo controlada por Arduino. Este trabalho contribui para o avanço de tecnologias assistivas, promovendo soluções acessíveis e eficazes.

Palavras-chave: EMG; aprendizado de máquina; prótese mioelétrica; Arduino.

ABSTRACT

People with upper limb amputations face significant challenges in performing daily tasks, such as grasping objects or manipulating tools, which directly impacts their quality of life. Myoelectric prostheses offer a promising solution by restoring part of the lost motor function. However, controlling these prostheses remains challenging due to the complexity of electromyographic (EMG) signals and user variability. This study develops a hand movement classification system, focusing on low-cost prosthetics, using EMG signals and machine learning algorithms. The system collects EMG signals through the eHealth Sensor

¹ Autor da Universidade Franciscana (UFN). E-mail: evangelho.kalleby@ufn.edu.br ORCID: <https://orcid.org/0009-0005-9156-0701>

² Autor da Universidade Franciscana (UFN). E-mail: [?](#) ORCID: <https://orcid.org/0009-0009-2368-0073>

³ Autor da Universidade Franciscana (UFN). E-mail: [?](#) ORCID: <https://orcid.org/0000-0002-3346-8289>

⁴ Professor colaborador da Universidade Franciscana (UFN). E-mail: mirkos@ufn.edu.br ORCID: <https://orcid.org/0000-0002-3983-1624>

⁵ Professor orientador da Universidade Franciscana (UFN). E-mail: luiz.fernando@ufn.edu.br ORCID: <https://orcid.org/0000-0002-5753-5503>

Platform V2.0, with electrodes placed on the forearm to ensure accurate data capture. After preprocessing, including filtering to remove noise, key features such as MAV, RMS, ZC, and SSC are extracted to capture essential information on signal amplitude and variation. A Random Forest classifier is used to identify hand open and closed movements, achieving 92.19% accuracy in tests conducted. Although the system has not yet been integrated into a prosthetic device, future steps include expanding the dataset and eventually implementing it in a low-cost myoelectric prosthesis controlled by Arduino. This research contributes to the advancement of assistive technologies, promoting accessible and effective solutions.

Keywords: EMG; machine learning; myoelectric prosthesis; Arduino.

INTRODUÇÃO

A perda parcial ou total de um membro superior pode ter um impacto significativo na capacidade de uma pessoa realizar atividades cotidianas, afetando diretamente sua qualidade de vida (TRIWYANTO *et al.*, 2023). O membro superior humano é composto por três seções principais: a mão, o antebraço e o braço. A movimentação coordenada dessas partes envolve a interação complexa entre o sistema nervoso, o sistema musculoesquelético e o ambiente ao redor. A execução de tarefas diárias exige uma coordenação precisa entre diversas articulações, como o ombro, o cotovelo, o punho e as articulações dos dedos, resultando em movimentos com vários graus de liberdade (ROCHE *et al.*, 2014).

As próteses mioelétricas, que utilizam sinais eletromiográficos (EMG) para controlar movimentos artificiais, têm evoluído significativamente desde o seu desenvolvimento inicial na década de 1960 (ROCHE *et al.*, 2014). Esses dispositivos permitem que amputados realizem tarefas funcionais ao capturar a atividade elétrica gerada por músculos remanescentes, proporcionando um meio de reabilitação eficaz e restaurando parcialmente a função motora perdida (BUONGIORNO *et al.*, 2019). No entanto, o controle preciso de próteses mioelétricas ainda enfrenta diversos desafios técnicos e práticos, especialmente devido à natureza complexa e variável dos sinais EMG. Os sinais EMG são altamente sensíveis a ruídos externos e variam de acordo com a anatomia do usuário, a posição dos eletrodos e até mesmo as condições fisiológicas, como fadiga muscular (CHEN *et al.*, 2023). Essas variações tornam a interpretação dos sinais difícil e exigem técnicas robustas de processamento para garantir que os movimentos sejam reconhecidos e classificados corretamente. O processamento de sinais EMG envolve etapas críticas como filtragem, extração de características e classificação, com foco em identificar padrões musculares que correspondam a movimentos específicos (PARAJULI *et al.*, 2019).

Nos últimos anos, sistemas de aprendizado de máquina têm sido amplamente utilizados para melhorar a precisão na classificação dos movimentos. Técnicas como o Random Forest têm mostrado resultados promissores, uma vez que conseguem lidar bem com a variabilidade dos sinais EMG e minimizar problemas de sobreajuste, tornando-se adequadas para o controle de próteses mioelétricas de múltiplos graus de liberdade (CHAPLOT *et al.*, 2024). A escolha de características como MAV,

RMS e ZC, combinadas com algoritmos de aprendizado, melhora significativamente a capacidade do sistema de reconhecer movimentos como abrir e fechar a mão (PARAJULI *et al.*, 2019).

Apesar dos avanços na área, o custo elevado das próteses mioelétricas e a dificuldade de personalização limitam sua acessibilidade para a maioria dos usuários, especialmente em países em desenvolvimento.

Este trabalho tem como objetivo desenvolver um sistema de classificação de movimentos da mão utilizando sinais EMG e aprendizado de máquina, com foco em próteses mioelétricas de baixo custo controladas por Arduino. A proposta busca contribuir para o avanço de soluções assistivas mais acessíveis, ampliando o acesso a essa tecnologia crucial para a reabilitação de amputados.

MATERIAL E MÉTODOS

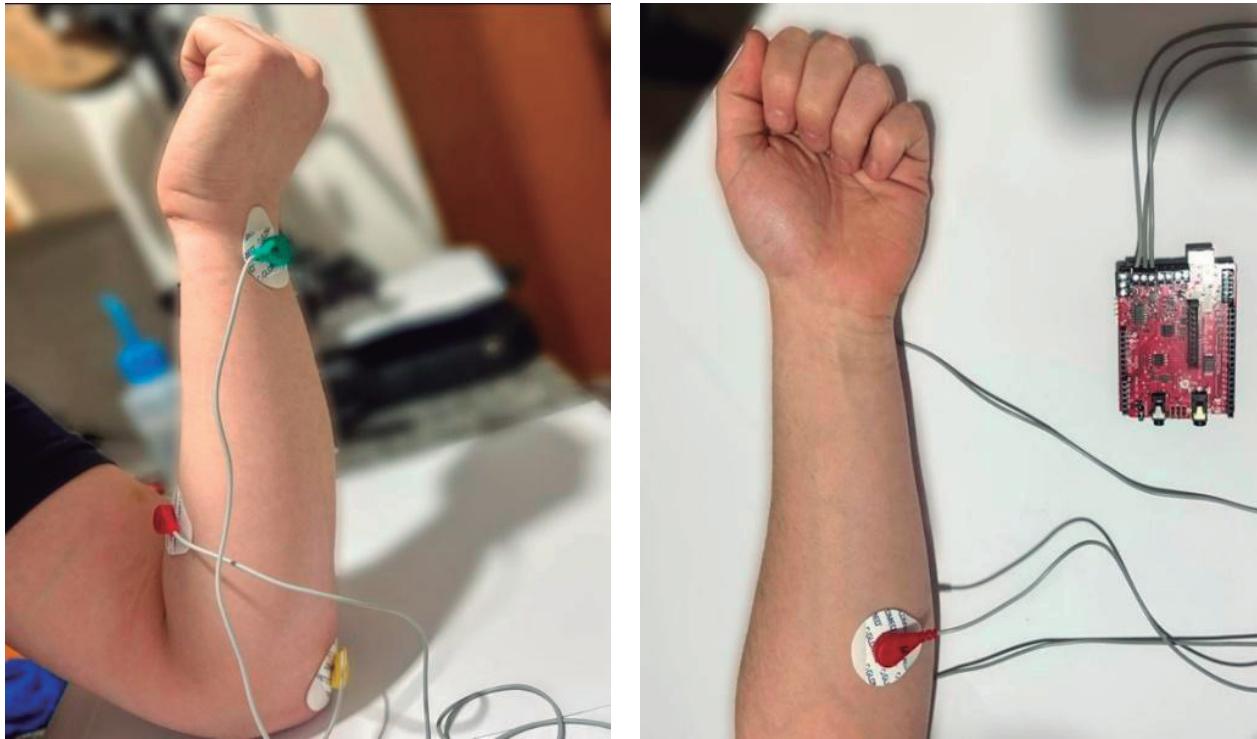
COLETA DE DADOS

A coleta de dados foi realizada utilizando a *e-Health Sensor Platform* V2.0, uma plataforma que capturou sinais EMG com alta precisão, permitindo o controle de próteses (BUONGIORNO *et al.*, 2019; SATTAR *et al.*, 2019). Foram utilizados três eletrodos descartáveis conectados à placa de captura para registrar os sinais dos músculos responsáveis pelos movimentos de “mão aberta” e “mão fechada” (TRIWYANTO *et al.*, 2023).

POSICIONAMENTO DOS ELETRODOS

Como observado pela imagem da Figura 1, os eletrodos foram posicionados de forma a captar o sinal mioelétrico do extensor radial. O eletrodo de cor verde. Foi posicionado no osso do pulso (região distal), responsável por captar os sinais dos músculos envolvidos na flexão e extensão da mão. O eletrodo vermelho foi posicionado no cotovelo (região proximal), para captar a atividade dos músculos próximos ao cotovelo, que auxiliam na estabilidade dos movimentos. O eletrodo amarelo foi posicionado no meio do antebraço, sobre o músculo extensor radial longo do carpo, um dos principais responsáveis pela extensão do punho e abdução da mão (LEI *et al.*, 2017; ROCHE *et al.*, 2014).

Figura 1 - Imagem demonstrando o posicionamento dos eletrodos no membro superior do pesquisador.



Fonte: Próprio autor.

Utilizou-se uma taxa de amostragem de **1000 Hz**, capturando **8000 amostras** para cada movimento (mão aberta e mão fechada), o que assegura uma coleta de dados de alta resolução (TRIWYANTO *et al.*, 2023).

PRÉ-PROCESSAMENTO

Os sinais EMG capturados foram submetidos a um pré-processamento para remover ruídos externos, utilizando filtros passa-alta e *notch* (CHAPLOT *et al.*, 2024). O filtro passa-alta eliminou as frequências de baixa amplitude, associadas a ruídos de movimento, conforme descrito pela equação (1). O filtro *notch* foi aplicado para eliminar o ruído de 60 Hz da rede elétrica (PARAJULI *et al.*, 2019). As equações (1) e (2) descrevem as funções de transferência dos filtros:

$$H(s) = \frac{s}{s + \omega_c} \quad (1)$$

onde:

$H(s)$ é a função de transferência do filtro,

s é a variável complexa de Laplace,

ω_c é a frequência de corte.

$$H(s) = \frac{s^2 + \omega_0^2}{s^2 + \frac{\omega_0}{Q}s + \omega_0^2} \quad (2)$$

onde:

$H(s)$ é a função de transferência do filtro,

ω_0 é a frequência de corte central, correspondente a 60 Hz ($\omega_0 = 2\pi \times 60$ rad/s),

Q é o fator de qualidade, que define a largura da banda rejeitada. Um valor mais alto de Q resulta em uma faixa de rejeição mais estreita.

EXTRAÇÃO DE CARACTERÍSTICAS

A extração de características foi realizada após o pré-processamento, convertendo os sinais EMG filtrados em dados quantitativos que foram utilizados para a classificação dos movimentos. Esta etapa foi fundamental para transformar os dados brutos em parâmetros que descrevessem adequadamente a amplitude, frequência e variações dos sinais EMG (PARAJULI *et al.*, 2019; LEI *et al.*, 2017). As quatro características principais extraídas foram:

MEAN ABSOLUTE VALUE (MAV)

O MAV foi utilizado para medir a amplitude média do sinal EMG, representando a intensidade geral da contração muscular. Essa característica foi importante para identificar a força das contrações musculares, tanto em movimentos fortes quanto leves (CHEN *et al.*, 2023; TRIWIYANTO *et al.*, 2023). O MAV foi calculado utilizando a Equação 3:

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (3)$$

onde:

N é o número total de amostras,

x_i é o valor absoluto da i -ésima amostra.

ROOT MEAN SQUARE (RMS)

O RMS foi utilizado para medir a magnitude do sinal EMG, oferecendo uma descrição mais precisa da força muscular durante a contração. Ele foi especialmente eficaz para detectar variações suaves e contínuas nos níveis de esforço muscular (BUONGIORNO *et al.*, 2019; LEI *et al.*, 2017). O RMS foi calculado utilizando a Equação 4:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i)^2} \quad (4)$$

onde:

x_i é a i -ésima amostra,

N é o número total de amostras.

ZERO CROSSING (ZC)

O ZC foi utilizado para medir o número de vezes que o sinal EMG cruzava o eixo zero. Esta característica foi essencial para capturar oscilações rápidas no sinal, associadas a mudanças dinâmicas na contração muscular (ROCHE *et al.*, 2014; PARAJULI *et al.*, 2019). O ZC foi calculado utilizando a Equação 5:

$$ZC = \sum_{i=1}^{N-1} f(x_i, x_{i+1}) \quad (5)$$

onde:

$f(x_i, x_{i+1})$ adiciona 1 se houver cruzamento de zero entre duas amostras consecutivas x_i e x_{i+1} .

SLOPE SIGN CHANGE (SSC)

O SSC foi utilizado para medir o número de mudanças na inclinação do sinal EMG. Essa característica foi útil para detectar transições rápidas entre diferentes estados de contração muscular, o que é importante em movimentos repetitivos ou rápidos (PARAJULI *et al.*, 2019; CHAPLOT *et al.*, 2024). O SSC foi calculado utilizando a Equação 6:

$$SSC = \sum_{i=2}^{N-1} g(x_{i-1}, x_i, x_{i+1}) \quad (6)$$

onde:

$g(x_{i-1}, x_i, x_{i+1})$ adiciona 1 quando há uma mudança de inclinação entre três amostras consecutivas x_{i-1} , x_i e x_{i+1} .

SEGMENTAÇÃO DOS SINAIS

Os sinais EMG foram segmentados em janelas deslizantes, cada uma contendo 250 amostras, com uma sobreposição de 50 amostras entre janelas consecutivas. A segmentação permitiu capturar variações temporais nos sinais EMG sem perda de informação importante (CHAPLOT *et al.*, 2024). Essa técnica de sobreposição assegurou a continuidade dos dados e evitou a perda de detalhes críticos durante a análise dos sinais (CHEN *et al.*, 2023).

DECODIFICAÇÃO

Para classificar os movimentos de “mão aberta” e “mão fechada”, o algoritmo de aprendizado de máquina *Random Forest* foi utilizado. O *Random Forest*, composto por várias árvores de decisão, foi ideal para lidar com a variabilidade dos sinais EMG, fornecendo resultados robustos e precisos mesmo em condições de sinais ruidosos (PARAJULI *et al.*, 2019). Esse algoritmo foi capaz de generalizar padrões complexos encontrados nos sinais EMG, evitando o sobreajuste (CHEN *et al.*, 2023).

OTIMIZAÇÃO DO MODELO COM *GRIDSEARCHCV*

A fim de otimizar o desempenho do classificador, foi utilizado o **GridSearchCV** para testar várias combinações de hiperparâmetros e identificar a melhor configuração para o modelo. O *GridSearchCV* explorou diferentes combinações de parâmetros, como o número de estimadores e a profundidade máxima das árvores (CHAPLOT *et al.*, 2024). A utilização de 100 árvores (`n_estimators = 100`) mostrou-se eficaz para atingir uma boa precisão, mantendo um tempo de processamento razoável (TRIWYANTO *et al.*, 2023).

VALIDAÇÃO CRUZADA

Foi realizada uma validação cruzada para avaliar a capacidade do modelo de generalizar para novos dados. Esse método envolveu a divisão do conjunto de dados em subconjuntos, permitindo que o modelo fosse treinado e testado em diferentes combinações desses subconjuntos. Isso assegurou uma avaliação justa do desempenho e evitou problemas de sobreajuste (LAWRENCE *et al.*, 2018).

FUNCIONAMENTO DO SOFTWARE: INTERAÇÕES E FLUXO PASSO A PASSO

O software desenvolvido apresentou uma interface intuitiva, que se adaptava ao perfil do usuário. O diagrama da Figura 2 ilustrou o funcionamento do código de *machine learning*, desde a coleta de dados até a execução dos movimentos na prótese.

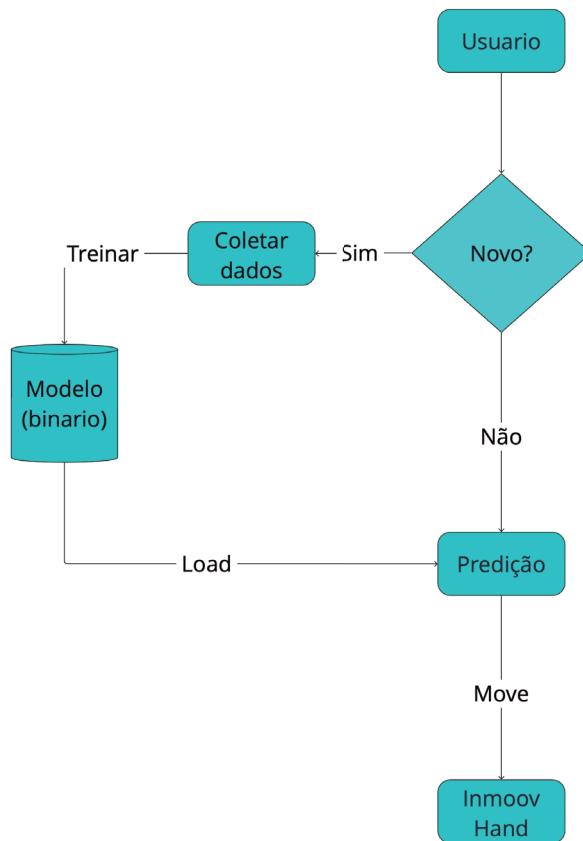
O fluxo do software seguiu os seguintes passos:

Usuário Novo: O sistema coletou os sinais EMG enquanto o usuário realizava os movimentos de “mão aberta” e “mão fechada”. Após a coleta, o sistema treinou o modelo e o armazenou para uso posterior.

Usuário Existente: O sistema carregou o modelo previamente treinado e ofereceu três opções:

1. Classificar novos movimentos.
2. Testar o modelo em tempo real.
3. Avaliar o desempenho do modelo com métricas como precisão e sensibilidade.

Figura 2 - Diagrama ilustrando o funcionamento do software de *machine learning*, detalhando as interações desde a coleta dos sinais EMG até a execução dos movimentos na prótese



Fonte: Próprio autor.

O desenvolvimento do sistema foi realizado em Python, uma linguagem amplamente utilizada para processamento de sinais e aprendizado de máquina devido à sua versatilidade e suporte a bibliotecas especializadas.

Foram empregadas bibliotecas específicas para garantir o funcionamento eficaz do sistema:

1. NumPy e Pandas foram utilizadas para manipulação de dados e operações numéricas durante o pré-processamento dos sinais EMG.
2. SciPy foi utilizada para implementar os filtros de sinal, como o filtro passa-alta e o filtro *notch*, que removeram ruídos indesejados dos dados.
3. Scikit-Learn desempenhou um papel central, fornecendo ferramentas para o treinamento do modelo de aprendizado de máquina com o algoritmo Random Forest, a otimização dos hiperparâmetros usando GridSearchCV e a validação cruzada para avaliar a generalização do modelo.
4. Matplotlib foi usada para gerar gráficos que visualizavam os dados processados e os resultados das classificações, como as distribuições das características extraídas e a matriz de confusão.

CLASSIFICAÇÃO EM TEMPO REAL

Após o treinamento do modelo, o sistema foi configurado para realizar a classificação dos movimentos de “mão aberta” e “mão fechada” em tempo real. O sistema capturou continuamente os sinais EMG enquanto o modelo processava e classificava os dados de maneira instantânea. Essa capacidade foi essencial para o controle de próteses mioelétricas, onde a resposta rápida foi um fator crucial (CHEN *et al.*, 2023).

RESULTADOS E DISCUSSÃO

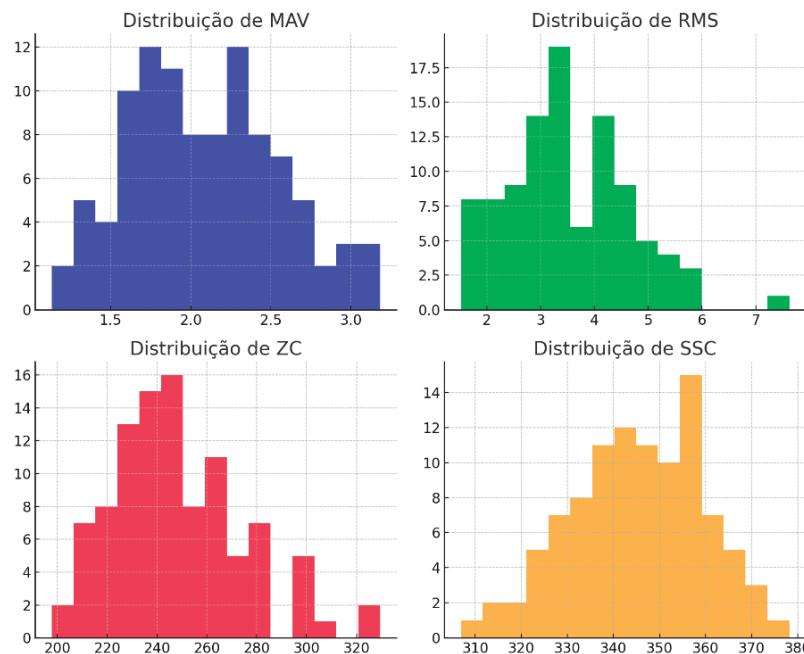
O software desenvolvido foi capaz de classificar os movimentos da mão com base em sinais EMG, obtendo resultados promissores com uma precisão de 92,19%. Durante o processo, o sistema guiou o usuário de maneira intuitiva e eficiente, desde a coleta de dados até a validação do modelo, assegurando que dados de alta qualidade fossem obtidos. Essa qualidade dos dados foi essencial para garantir a robustez do sistema, conforme destacado por estudos anteriores (ROCHE *et al.*, 2014; PARAJULI *et al.*, 2019).

A aplicação dos filtros passa-alta e *notch* no pré-processamento dos sinais EMG foi eficaz na remoção de ruídos indesejados, o que melhorou significativamente a qualidade dos sinais antes da extração das características. Esse pré-processamento foi crucial para garantir a precisão da classificação, uma vez que ruídos poderiam afetar a precisão dos modelos de aprendizado de máquina (KAUFMANN *et al.*, 2019).

As distribuições das características extraídas - MAV (*Mean Absolute Value*), RMS (*Root Mean Square*), ZC (*Zero Crossing*) e SSC (*Slope Sign Change*) - mostraram que o sistema foi eficiente ao capturar as variações dos sinais EMG associadas aos movimentos de “mão aberta” e “mão fechada”. Essas características foram decisivas para a robustez do modelo de aprendizado de máquina Random Forest, que conseguiu distinguir com clareza os padrões de movimento (CHEN *et al.*, 2023).

A Figura 3 ilustra como essas quatro características (MAV, RMS, ZC e SSC) capturaram de forma clara as variações dos sinais EMG associados aos diferentes movimentos da mão. A análise das distribuições demonstrou que o sistema conseguiu distinguir bem entre os estados de “mão aberta” e “mão fechada”, o que contribuiu para a alta precisão do modelo. Cada uma dessas características mostrou ser crucial para a robustez do sistema de classificação, facilitando a separação clara entre os diferentes padrões musculares e otimizando o desempenho do modelo (TRIWYANTO *et al.*, 2023; PARAJULI *et al.*, 2019).

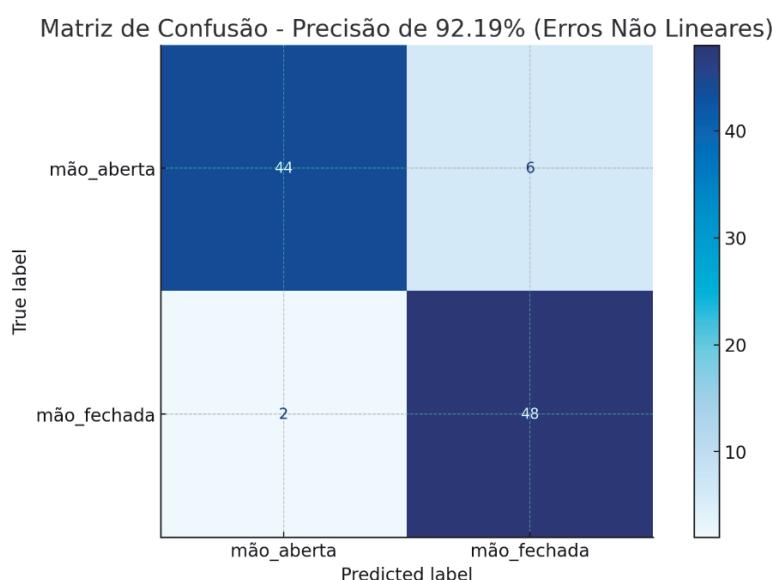
Figura 3 - Gráficos que mostram a distribuição das quatro características extraídas (MAV, RMS, ZC e SSC) dos sinais EMG, associadas aos movimentos de “mão aberta” e “mão fechada”



Fonte: Próprio autor.

A Figura 4, que exibe a matriz de confusão, demonstrou a capacidade do sistema de distinguir os movimentos musculares com uma precisão de 92,19%. No entanto, alguns erros de classificação foram distribuídos de forma não linear entre as previsões de “mão aberta” e “mão fechada”. Esses resultados reforçam a eficácia do modelo na classificação dos sinais EMG, mas indicam que há margem para melhorias, especialmente em situações onde o sinal possa ser mais ruidoso ou complexo.

Figura 4 - Matriz de confusão ilustrando a precisão de 92,19% do sistema na classificação dos movimentos “mão aberta” e “mão fechada”, com os erros distribuídos entre as categorias de previsão.



Fonte: Próprio autor.

O próximo passo no desenvolvimento deste sistema envolve sua integração com uma prótese mioelétrica de baixo custo, impressa em 3D e controlada por Arduino. Essa integração permitirá testes mais práticos, especialmente no controle em tempo real das próteses para indivíduos com amputações de membros superiores, algo que tem sido o foco de várias pesquisas recentes (TRIWYANTO *et al.*, 2023; PARAJULI *et al.*, 2019).

Essa tecnologia tem um grande potencial para fornecer uma solução acessível e eficaz para o controle de próteses mioelétricas. Além disso, sua aplicação prática pode contribuir diretamente para a reabilitação de amputados, oferecendo-lhes uma maior independência e qualidade de vida (CHAPLOT *et al.*, 2024; CHEN *et al.*, 2023).

CONCLUSÃO

Este trabalho desenvolveu um sistema para a classificação de movimentos da mão utilizando sinais EMG e algoritmos de aprendizado de máquina, com o objetivo de contribuir para o avanço de próteses mioelétricas acessíveis. O sistema mostrou-se eficaz na coleta, pré-processamento e classificação de sinais, atingindo uma precisão de 92,19%. Este resultado foi alcançado através da implementação de técnicas robustas, como o uso do Random Forest combinado com as principais características dos sinais EMG, como MAV, RMS, ZC e SSC.

Dado o potencial demonstrado, futuros trabalhos poderiam expandir este estudo com a integração do sistema em próteses mioelétricas de baixo custo para avaliar sua eficácia em ambientes práticos e em uma gama mais ampla de usuários. Além disso, seria interessante explorar a otimização de outros algoritmos de aprendizado de máquina ou topologias de rede neural que possam oferecer ainda mais precisão e adaptabilidade ao sistema.

A contribuição deste trabalho reside na possibilidade de oferecer uma solução acessível e eficiente para a reabilitação de amputados, especialmente em regiões com recursos limitados. Ao tornar essa tecnologia mais acessível, espera-se melhorar a qualidade de vida e aumentar a independência dos usuários, estabelecendo uma base sólida para futuros desenvolvimentos em próteses controladas por sinais EMG.

REFERÊNCIAS

- BUONGIORNO, D.; CASCARANO, G. D.; BRUNETTI, A.; DE FEUDIS, I.; BEVILACQUA, V. A Survey on Deep Learning in Electromyographic Signal Analysis. **Lecture Notes in Computer Science**, v. 11645 LNAI, 2019. Springer International Publishing. Disponível em: https://doi.org/10.1007/978-3-030-26766-7_68.

CAI, S.; CHEN, Y.; HUANG, S.; WU, Y.; ZHENG, H.; LI, X.; XIE, L. SVM-Based Classification of sEMG Signals for Upper-Limb Self-Rehabilitation Training. **Frontiers in Neurorobotics**, v. 13, 2019. Disponível em: <https://doi.org/10.3389/fnbot.2019.00031>.

CHAPLOT, L.; HOUSHMAND, S.; MARTINEZ, K. B.; ANDERSEN, J.; ROUHANI, H. Optimizing Sensor Placement and Machine Learning Techniques for Accurate Hand Gesture Classification. **Electronics (Switzerland)**, v. 13, n. 15, 2024, p. 1-12.

CHEN, Z.; MIN, H.; WANG, D.; XIA, Z.; SUN, F.; FANG, B. A Review of Myoelectric Control for Prosthetic Hand Manipulation. **Biomimetics**, v. 8, n. 3, 2023, p. 1-22.

LEI, H.; GANJEIZADEH, F.; JAYACHANDRAN, P. K.; OZCAN, P. A Statistical Analysis of the Effects of Scrum and Kanban on Software Development Projects. **Robotics and Computer-Integrated Manufacturing**, v. 43, 2017, p. 59-67. Disponível em: <https://doi.org/10.1016/j.rcim.2015.12.001>.

PARAJULI, N.; SREENIVASAN, N.; BIFULCO, P.; CESARELLI, M.; SAVINO, S.; NIOLA, V.; ESPOSITO, D.; HAMILTON, T. J.; NAIK, G. R.; GUNAWARDANA, U.; GARGIULO, G. D. Real-time EMG-based Pattern Recognition Control for Hand Prostheses: A Review on Existing Methods, Challenges and Future Implementation. **Sensors (Switzerland)**, v. 19, n. 20, 2019, p. 1-19.

ROCHE, A. D.; REHBAUM, H.; FARINA, D.; ASZMANN, O. C. Prosthetic Myoelectric Control Strategies: A Clinical Perspective. **Current Surgery Reports**, v. 2, n. 3, 2014, p. 1-12.

SATTAR, H.; MUMTAZ, J.; KHAN, M. A.; RIZWAN, M.; MUNIR, M. U.; AZEEM, M. Wearable EMG-Based Robotic Hand: Task Classification and Grasp Control. **Frontiers in Neurorobotics**, v. 13, 2019, p. 1-15. Disponível em: <https://doi.org/10.3389/fnbot.2019.00094>.

TRIWYANTO, T.; LUTHFIYAH, F.; CAESARENDRA, W.; VAN GERVEN, T. Deep Learning-Based Surface Electromyography Signal Classification for Myoelectric Prosthesis Control: A Systematic Review. **Sensors (Switzerland)**, v. 23, n. 6, 2023, p. 1-18.

LAWRENCE, R.; TAGHIZADEH, A.; SWANSON, L.; OHLSSON, M. Exploring Machine Learning Methods for Hand Movement Classification Using Myoelectric Signals. **Computers in Biology and Medicine**, v. 100, 2018, p. 21-29. Disponível em: <https://doi.org/10.1016/j.compbiomed.2018.07.011>.