



**Universidade Federal de Uberlândia  
Faculdade de Engenharia Elétrica - FEELT  
Graduação em Engenharia Biomédica**

**JOÃO VITOR SILVA**

**ANÁLISE COMPARATIVA DE MODELOS DE APRENDIZADO DE  
MÁQUINA PARA A CLASSIFICAÇÃO DE MOVIMENTOS FINOS DE  
MÃO COM SINAIS DE ELETROMIOGRAFIA DE SUPERFÍCIE**

Uberlândia  
2025

**JOÃO VITOR SILVA**

**ANÁLISE COMPARATIVA DE MODELOS DE APRENDIZADO DE  
MÁQUINA PARA A CLASSIFICAÇÃO DE MOVIMENTOS FINOS DE  
MÃO COM SINAIS DE ELETROMIOGRAFIA DE SUPERFÍCIE**

Trabalho apresentado como requisito parcial de avaliação na disciplina Trabalho de Conclusão de Curso de Engenharia Biomédica da Universidade Federal de Uberlândia.

Orientador: Prof. Dr. Alcimar Barbosa Soares

Uberlândia  
2025

## **AGRADECIMENTOS**

Agradeço, primeiramente, aos meus pais, Andrea da Silva Araujo e João Batista da Silva, por sempre me incentivarem na busca pelo conhecimento e por todo o apoio incondicional. Aos meus irmãos, por estarem sempre disponíveis para um conselho. Agradeço também a todos os meus familiares, cujo apoio e presença foram fundamentais nesta jornada.

Ao meu orientador, Professor Dr. Alcimar Barbosa Soares, expresso minha profunda gratidão e admiração pela orientação neste trabalho. Agradeço ao Laboratório de Engenharia Biomédica (BioLab) e a todos os seus membros, que não apenas propiciaram um excelente ambiente de pesquisa, mas também um lugar acolhedor onde pude crescer e cultivar grandes amizades.

Aos amigos que construí durante este período, deixo meu mais profundo agradecimento pelo companheirismo, pelas palavras de incentivo, pelo apoio mútuo e pelos momentos de descontração que tornaram essa trajetória acadêmica mais leve e divertida.

Por fim, agradeço a cada pessoa que, de alguma forma, contribuiu para a realização deste trabalho. Muito obrigado por fazerem parte da minha jornada e por tornarem tudo isso possível.

## RESUMO

O controle intuitivo de próteses de mão multifuncionais representa um desafio significativo na engenharia de reabilitação, especialmente na classificação de movimentos finos a partir de sinais de sEMG. Este trabalho apresenta uma análise comparativa sistemática de três paradigmas de aprendizado de máquina: LDA, SVM e CNN. Para isso, sinais de sEMG de três canais foram adquiridos de cinco voluntários saudáveis durante a execução de sete movimentos finos da mão. Dos modelos clássicos, LDA e SVM, foi extraído um conjunto de características no domínio do tempo, enquanto a CNN foi treinada de forma ponta a ponta com o sinal sEMG bruto. Os modelos foram avaliados e comparados em termos de acurácia de classificação, robustez inter-sujeito, impacto do número de classes para classificação e custo-benefício computacional. Os resultados demonstraram uma clara hierarquia de desempenho, com a CNN alcançando a maior acurácia média de validação com 96,46%, seguida pelo SVM em 88,58% e pelo LDA 75,12%. A CNN também se mostrou o modelo mais robusto, com a menor variabilidade de desempenho entre os participantes. A análise de custo-benefício quantificou o trade-off fundamental, onde a superioridade da CNN em performance contrasta com seu alto custo de treinamento em comparação com a eficiência dos modelos clássicos. Conclui-se que a CNN representa o paradigma de melhor desempenho para classificação de movimentos finos de dígitos, e este estudo fornece uma base de evidências quantitativa para guiar a seleção de algoritmos no desenvolvimento de futuras interfaces mioelétricas.

**Palavras-chave:** Eletromiografia de superfície, classificação de movimentos, aprendizado de máquina, redes neurais convolucionais, próteses mioelétricas.

## ABSTRACT

The intuitive control of multifunctional hand prostheses represents a significant challenge in rehabilitation engineering, especially in the classification of fine hand movements from surface electromyography (sEMG) signals. This work presents a systematic comparative analysis of three machine learning paradigms: Linear Discriminant Analysis (LDA), Support Vector Machine (SVM), and Convolutional Neural Network (CNN). For this purpose, three-channel sEMG signals were acquired from five healthy volunteers during the execution of seven fine hand movements. For the classical models (LDA and SVM), a set of time-domain features was extracted, whereas the CNN was trained end-to-end with the raw sEMG signal. The models were evaluated and compared in terms of classification accuracy, inter-subject robustness, the impact of the number of classes, and computational cost-benefit. The results demonstrated a clear performance hierarchy, with the CNN achieving the highest mean validation accuracy of 96.46%, followed by the SVM at 88.58% and the LDA at 75.12%. The CNN also proved to be the most robust model, showing the lowest performance variability among participants. The cost-benefit analysis quantified the fundamental trade-off, where the CNN's superior performance contrasts with its high training cost compared to the efficiency of classical models. It is concluded that the CNN represents the best-performing paradigm for the classification of fine finger movements, and this study provides a quantitative evidence base to guide the selection of algorithms in the development of future myoelectric interfaces.

**Keywords:** Surface electromyography, movement classification, machine learning, convolutional neural networks, myoelectric prostheses.

## LISTA DE ILUSTRAÇÕES

Figura 1 - Exemplo de pipeline utilizado para classificação de padrões com sEMG.	18
Figura 2 - Visualização, em corte transversal, do posicionamento dos eletrodos no antebraço.....	29
Figura 3 - Ilustração das tarefas definidas para o protocolo experimental.....	30
Figura 4 - Visualização de um bloco de 10 contrações do sinal filtrado e espectro de frequência.....	32
Figura 5 - Visualização da extração de intervalos de interesse do sinal.....	33
Figura 6 - Demonstração da aplicação de janela deslizante no sinal.....	34
Figura 7 - Pipeline de pré-processamento dos dados de sEMG.....	35
Figura 8 - Esquema de Validação Cruzada K-Fold.....	36
Figura 9 - Arquitetura proposta para CNN.....	39
Figura 10 - Comparativo do Desempenho de Classificação Entre Paradigmas.....	43
Figura 11-A - Matriz de Confusão Normalizada Modelo LDA.....	44
Figura 11-B - Matriz de Confusão Normalizada Modelo SVM.....	45
Figura 11-C - Matriz de Confusão Normalizada Modelo CNN.....	45
Figura 12 - Desempenho dos Classificadores entre os grupos de 7 e 5 classes.....	46

## LISTA DE TABELAS

Tabela 1 - Comparação entre paradigmas de classificação para sEMG.....	24
Tabela 2 - Desempenho Detalhado do Classificador LDA para 7 Classes.....	41
Tabela 3 - Desempenho Detalhado do Classificador SVM para 7 Classes.....	42
Tabela 4 – Desempenho Detalhado do Classificador CNN para 7 Classes.....	42
Tabela 5 - Resumo Comparativo do Desempenho dos Modelos.....	47

## **LISTA DE ABREVIATURAS E SIGLAS**

- CNN - Rede Neural Convolucional
- DoFs - Graus de Liberdade
- FFT - Transformada Rápida de Fourier
- LDA - Análise Discriminante Linear
- MAV - Valor Médio Absoluto
- PCA - Análise de Componentes Principais
- RMS - Valor Médio Quadrático
- RP - Reconhecimento de Padrões
- sEMG - Eletromiografia de superfície
- SSC - Mudança de Sinal da Inclinação
- SVM - Máquina de Vetores de Suporte
- WL - Comprimento de Onda
- ZC - Cruzamento por Zero



## SUMÁRIO

<b>1 INTRODUÇÃO.....</b>	<b>10</b>
1.1 Contextualização.....	10
1.2 Objetivos.....	12
1.2.1 Objetivo geral.....	12
1.2.2 Objetivos específicos.....	12
1.2.3 Justificativa.....	12
<b>2 REVISÃO BIBLIOGRÁFICA.....</b>	<b>14</b>
2.1 Eletromiografia de Superfície e o Controle Mioelétrico.....	14
2.2 A Gênese Fisiológica do Sinal Mioelétrico.....	15
2.3 Estratégias de Controle Mioelétrico.....	16
2.4 Pipeline de Reconhecimento de Padrões em sEMG.....	17
2.5 Filtragem.....	19
2.6 Segmentação do Sinal: Janelas e Sobreposição.....	20
2.7 Normalização.....	21
2.8 Extração de Características para Modelos.....	22
2.8.1 Domínio Temporal.....	22
2.8.2 Domínio da Frequência.....	23
2.9 Paradigmas de Classificação para Sinais Mioelétricos.....	24
2.9.1 Classificadores Clássicos.....	25
2.9.2 Paradigma de Aprendizado Profundo.....	26
2.10 Desafios e Limitações Atuais no Controle Mioelétrico.....	26
<b>3 METODOLOGIA.....</b>	<b>28</b>
3.1 Aquisição de Dados e Protocolo Experimental.....	28
3.1.1 Participantes.....	28
3.1.2 Aquisição de dados.....	28
3.1.3 Posicionamento dos Eletrodos.....	28
3.1.4 Procedimento experimental.....	29
3.2 Pré-processamento dos Dados.....	31
3.3 Processamento dos Dados.....	35
3.3.1 Análise Discriminante Linear (LDA).....	36
3.3.2 Máquina de Vetores de Suporte (SVM).....	37
3.3.3 Rede Neural Convolucional (CNN).....	37
3.4 Avaliações Comparativas.....	39
<b>4 RESULTADOS.....</b>	<b>41</b>
4.1 Desempenho de Classificação e Capacidade de Generalização.....	41
4.2 Desempenho Geral e Robustez Inter-sujeito.....	43
4.3 Analisar o efeito do número de classes no desempenho dos classificadores.....	44
4.4 Análise de Custo-Benefício Computacional.....	47
<b>5 DISCUSSÃO.....</b>	<b>48</b>
<b>6 CONCLUSÃO.....</b>	<b>51</b>
<b>7 REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>52</b>



# 1 INTRODUÇÃO

## 1.1 Contextualização

O avanço tecnológico das últimas décadas impulsionou diversas áreas de pesquisa voltadas à reabilitação humana, resultando em melhorias significativas na qualidade de vida de pessoas com deficiências motoras ou amputações. Nesse contexto, destaca-se o campo das interfaces mioelétricas, que utilizam a eletromiografia de superfície (sEMG) como um método robusto e não invasivo para capturar a intenção motora do usuário (Oskoei; Hu, 2007). A capacidade de decodificar a atividade muscular abriu caminho para o desenvolvimento de técnicas avançadas que interpretam esses sinais e replicam movimentos complexos em próteses de membros superiores (Pandey; Mishra, 2009).

Os primeiros sistemas convencionais de controle de próteses de mão, como o controle proporcional e o liga-desliga, operam a partir de um ou dois eletrodos. Nesses sistemas, o sinal registrado passava por um processamento simples para obtenção da envoltória, envolvendo filtragem passa-banda, retificação e filtragem passa-baixa. Em seguida, estabelecia-se um limiar para determinar o nível mínimo de contração necessário para acionar o movimento. Apesar de funcionais, esses métodos eram, em geral, limitados a poucos graus de liberdade (DoFs) (Hahne; Markovic; Farina, 2017; Ferris; Czerniecki; Hannaford, 2005). No modo proporcional, a velocidade do motor é diretamente relacionada à amplitude do sinal sEMG, contrações mais fortes resultam em movimentos mais rápidos, como o fechamento da mão. Já no modo liga-desliga, a velocidade é constante, permitindo o controle de até dois DoFs, normalmente restritos às ações de abrir e fechar a mão (Hahne; Markovic; Farina, 2017).

Como alternativa, surgiram modelos baseados em Reconhecimento de Padrões (RP), capazes de superar limitações como o baixo número de DoFs nos sistemas convencionais. Essa abordagem analisa o padrão de ativação de múltiplos músculos simultaneamente e aplica modelos de aprendizado de máquina treinados para decodificar e categorizar a intenção motora, viabilizando um controle mais complexo e multifuncional (Iqbal; Subramaniam; Shaniba, 2018). No entanto, a eficácia dos sistemas de RP é desafiada pela própria natureza do sinal mioelétrico: sendo não estacionário, suas propriedades estatísticas podem se alterar em curtos intervalos de tempo devido a fatores como deslocamento dos eletrodos e fadiga muscular. Essa

variabilidade inerente torna indispensável o uso de técnicas de aprendizado de máquina para o desenvolvimento de sistemas mais adaptativos e robustos (Kamavuako; Scheme; Englehart, 2014; Scheme; Englehart, 2011).

Tradicionalmente, o RP em sEMG utiliza modelos clássicos como a Análise Discriminante Linear (LDA), reconhecida por sua simplicidade e eficiência em sistemas embarcados (Chan; Green, 2007; Englehart; Hudgins, 2003), e as Máquinas de Vetores de Suporte (SVM), valorizadas por sua robustez (Oskoei; Hu, 2008). Ambos dependem de uma etapa fundamental: a extração manual de características, responsável por transformar o sinal pré-processado em um conjunto conciso de atributos representativos (Oskoei; Hu, 2007; Phinyomark *et al.*, 2010; Phinyomark *et al.*, 2013; Zardoshti *et al.*, 1993). Um exemplo amplamente adotado é o conjunto proposto por Hudgins *et al.* (2002), composto por quatro características no domínio do tempo: Valor Médio Absoluto, Comprimento de Onda, Mudança de Sinal da Inclinação e Cruzamentos por Zero. Embora eficaz, esse processo depende fortemente da habilidade de projetar atributos adequados, representando um gargalo para a escalabilidade e a generalização dos sistemas.

Com o avanço do poder computacional e da disponibilidade de dados, técnicas de aprendizado profundo como Redes Neurais Convolucionais (CNNs) têm se destacado como alternativa para superar a dependência da engenharia manual de características (Allard *et al.*, 2016; Atzori; Cognolato; Muller, 2016). Essas arquiteturas adotam um paradigma de aprendizado de ponta a ponta (end-to-end), no qual a rede aprende diretamente a mapear o sinal bruto para a saída final, sem a necessidade de etapas explícitas de extração manual. Apesar do custo computacional mais elevado, essa abordagem simplifica o pipeline, permite a descoberta automática de padrões relevantes e potencialmente aumenta a robustez do sistema, já que a seleção de características é orientada exclusivamente pelos dados (Côté-Allard *et al.*, 2017).

A complexidade da classificação de movimentos finos de mão, caracterizada por sinais com baixa amplitude e alta sobreposição muscular, continua sendo um desafio significativo na engenharia de reabilitação (Scheme; Englehart, 2011). Por essa razão, este trabalho propõe a análise comparativa entre os modelos LDA, SVM e CNN, que representam paradigmas linear, não-linear clássico e de aprendizado profundo, respectivamente, para fornecer uma base de evidências objetiva que possa identificar a abordagem mais eficaz para esse desafio.

## 1.2 Objetivos

### 1.2.1 *Objetivo geral*

O objetivo principal deste trabalho é realizar uma análise comparativa e sistemática do desempenho de três paradigmas distintos de aprendizado de máquina: LDA, SVM e CNN, na tarefa de classificação de sete movimentos finos da mão a partir de sinais de eletromiografia de superfície.

### 1.2.2 *Objetivos específicos*

Para atingir o objetivo geral, os seguintes objetivos específicos serão cumpridos:

- Comparar a acurácia de classificação e a capacidade de generalização dos três modelos.
- Analisar a robustez dos modelos frente à variabilidade inter-sujeito.
- Avaliar o impacto do número de classes no desempenho dos classificadores, comparando os resultados para 5 e 7 classes de movimento.
- Analisar o custo-benefício computacional de cada paradigma, contrastando a performance com o tempo de treinamento e a latência de inferência.

### 1.2.3 *Justificativa*

A escolha de um algoritmo para a classificação de sinais mioelétricos é uma etapa fundamental no desenvolvimento de interfaces homem-máquina. Cada abordagem de aprendizado de máquina possui um balanço particular entre acurácia, complexidade e necessidade de pré-processamento. Modelos clássicos como LDA e SVM, por exemplo, são bem estabelecidos, mas dependem de uma engenharia de características manual, enquanto abordagens mais recentes como as CNNs prometem aprender essas características de forma automática.

Nesse contexto, este trabalho se justifica pela oportunidade de realizar uma comparação sistemática e direta entre esses três paradigmas de classificação: um linear (LDA), um não-linear clássico (SVM) e um de aprendizado profundo (CNN). A avaliação desses modelos sob as mesmas condições experimentais, com um conjunto de dados focado em movimentos finos da mão, busca oferecer uma análise clara das

vantagens e desvantagens de cada método. A contribuição deste estudo é, portanto, fornecer uma análise comparativa e detalhada que possa servir de referência para futuros projetos acadêmicos e para a tomada de decisão no desenvolvimento de sistemas de controle mioelétrico.

## 2 REVISÃO BIBLIOGRÁFICA

### 2.1 Eletromiografia de Superfície e o Controle Mioelétrico

A eletromiografia de superfície é uma técnica não invasiva amplamente utilizada para analisar a atividade elétrica dos músculos esqueléticos (De Luca, 1997). Essa tecnologia tem se tornado essencial em áreas como fisioterapia, reabilitação, ergonomia, neurociência e, mais recentemente, no controle de próteses e interfaces homem-máquina por meio do controle mioelétrico (Farina *et al.*, 2014).

Segundo Merletti e Parker (2010), a sEMG permite a detecção dos sinais elétricos gerados pela ativação muscular, sendo particularmente útil para estudar padrões de recrutamento muscular em tempo real. Esses sinais são captados por eletrodos posicionados sobre a pele e refletem a atividade dos motoneurônios que comandam os músculos subjacentes.

O controle mioelétrico, por sua vez, refere-se ao uso dos sinais mioelétricos para operar dispositivos externos, como próteses robóticas. Essa aplicação tem ganhado destaque devido ao avanço da Engenharia Biomédica e dos algoritmos de processamento de sinais (Farina *et al.*, 2014). Ainda segundo o autor (2014, p. 798), "o controle mioelétrico baseado em sEMG representa uma das abordagens mais promissoras para a criação de sistemas intuitivos de interface homem-máquina".

Além disso, estudos recentes demonstram que o uso da sEMG em sistemas de controle pode contribuir significativamente para a personalização da reabilitação motora. Por exemplo, Oliveira *et al.* (2020) relatam que "a análise dos sinais eletromiográficos permite identificar padrões motores residuais, o que é fundamental para o desenvolvimento de próteses controladas por sinais musculares residuais em amputados".

Entretanto, o uso da EMG de superfície também apresenta desafios, especialmente relacionados à variabilidade interindividual e à interferência de ruídos externos. Como aponta De Luca (2006, p. 140), "a fidelidade do sinal EMG depende de fatores como a colocação dos eletrodos, a impedância da pele e a interferência de outros músculos próximos".

Apesar desses desafios, o avanço na filtragem e interpretação dos sinais tem ampliado as possibilidades de aplicação prática. Sistemas modernos utilizam inteligência artificial e aprendizado de máquina para interpretar os sinais EMG e

traduzir comandos musculares em movimentos robóticos precisos e adaptáveis, como evidenciam os trabalhos de Scheme e Englehart (2011).

Dessa forma, a integração entre a eletromiografia de superfície e o controle mioelétrico se configura como um campo multidisciplinar com grande potencial para promover a autonomia de pessoas com deficiência física e ampliar os horizontes da interação homem-máquina (Farina *et al.*, 2014; Scheme; Englehart, 2011).

## **2.2 A Gênese Fisiológica do Sinal Mioelétrico**

O sinal mioelétrico, também conhecido como sinal eletromiográfico, é uma manifestação elétrica da atividade muscular resultante da despolarização das fibras musculares esqueléticas (Basmajian; De Luca, 1985). Sua gênese fisiológica está diretamente relacionada à transmissão do impulso nervoso do sistema nervoso central para os músculos, gerando uma resposta elétrica mensurável que pode ser captada por eletrodos (De Luca, 1997).

Do ponto de vista neurofisiológico, o processo inicia-se com a ativação de um motoneurônio alfa, cuja terminação libera o neurotransmissor acetilcolina na junção neuromuscular. Esse neurotransmissor despolariza a membrana da fibra muscular, gerando um potencial de ação que se propaga ao longo da membrana da célula muscular (De Luca, 1997; Farina *et al.*, 2014). Segundo Guyton e Hall (2011, p. 142), “essa despolarização desencadeia uma série de eventos que culminam na contração muscular, sendo o sinal elétrico captado nesse processo o que se denomina sinal mioelétrico”.

Cada motoneurônio inerva diversas fibras musculares, formando uma unidade motora. A ativação sequencial ou simultânea de várias unidades motoras gera um somatório de potenciais de ação musculares. Como destaca De Luca (2002, p. 145), “o sinal EMG é o resultado da soma dos potenciais de ação de todas as fibras musculares ativadas sob o eletrodo, que são modulados no tempo e no espaço”.

Além disso, o sinal mioelétrico é influenciado por diversas variáveis fisiológicas e biomecânicas, como o número de unidades motoras recrutadas, a frequência de disparo neural, o tipo de fibra muscular envolvida (tipo I ou tipo II), e a profundidade das fibras em relação à pele (De Luca, 1997; Farina *et al.*, 2014).

Do ponto de vista técnico, os eletrodos de superfície captam essas variações



elétricas com precisão, mas a interpretação do sinal requer o conhecimento profundo dos mecanismos fisiológicos envolvidos. Segundo Mesin *et al.* (2004), a compreensão da gênese do sinal mioelétrico é fundamental para que se possa extrair informações significativas da eletromiografia, seja para aplicações clínicas, ergonômicas ou em interfaces de controle.

Portanto, a gênese do sinal mioelétrico envolve a interação entre o sistema nervoso e o sistema muscular, mediada por processos bioelétricos altamente organizados e coordenados. A leitura adequada desses sinais permite avanços importantes no monitoramento muscular, no controle de próteses e na reabilitação funcional (Basmajian; De Luca, 1985; Farina *et al.*, 2014).

## **2.3 Estratégias de Controle Mioelétrico**

O controle mioelétrico tem recebido destaque nos últimos anos, especialmente nas áreas de reabilitação, próteses ativas, exoesqueletos e interfaces homem-máquina (Englehart; Hudgins, 2003). Trata-se de uma técnica baseada na captação e interpretação dos sinais elétricos gerados pela contração dos músculos esqueléticos, os chamados sinais mioelétricos, para controlar dispositivos eletromecânicos (Farina *et al.*, 2014; Scheme; Englehart, 2011). Para garantir uma operação funcional, intuitiva e precisa, diversas estratégias de controle mioelétrico vêm sendo desenvolvidas e aprimoradas (Scheme; Englehart, 2011).

Segundo Parker, Englehart e Hudgins (2006), o controle proporcional fornece resposta contínua e direta ao sinal muscular, mas é limitado quando se busca controlar múltiplos DoFs simultaneamente. Segundo Farina *et al.*, (2014) as estratégias de controle mioelétrico podem ser agrupadas em duas categorias principais: controle proporcional e reconhecimento de padrões. No controle proporcional, a amplitude do sinal EMG é diretamente proporcional à velocidade ou força do movimento desejado.

Por outro lado, estratégias baseadas em reconhecimento de padrões utilizam algoritmos de aprendizado de máquina para identificar padrões específicos de atividade muscular associados a diferentes movimentos (Phinyomark *et al.*, 2013). Esses sistemas capturam características dos sinais de EMG e os classificam com base em bancos de dados previamente treinados (zScheme; Englehart, 2011). Farina *et al.* (2014) afirmam que os métodos baseados em reconhecimento de padrões

representam um avanço significativo ao permitir o controle de múltiplas funções com maior naturalidade e menor esforço cognitivo do usuário.

Além dessas, há ainda abordagens mais recentes como o controle baseado em modelos neuromusculares, que busca simular a fisiologia do sistema motor para gerar respostas mais naturais, e o controle adaptativo, no qual o sistema se ajusta continuamente às mudanças fisiológicas do usuário, como fadiga muscular ou variação na colocação dos eletrodos (Farina *et al.*, 2014; Jiang *et al.*, 2012).

Outra estratégia promissora é o controle de múltiplos graus de liberdade simultâneos, por meio de técnicas como regressão multivariada, redes neurais profundas e controle por estimativa de torque. De acordo com Jiang *et al.* (2012, p. 803), “os avanços em controle contínuo e simultâneo permitirão o desenvolvimento de próteses mais funcionais e com capacidade de realizar tarefas complexas com maior precisão”.

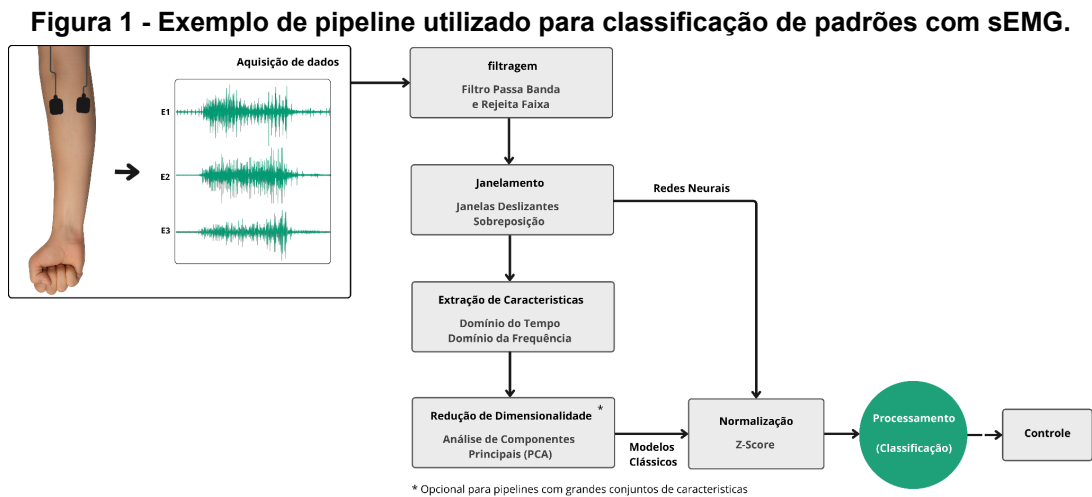
Contudo, a escolha da estratégia depende de fatores como o nível de amputação do usuário, a disponibilidade de massa muscular remanescente, o tipo de dispositivo a ser controlado e os requisitos de robustez e tempo real do sistema (Scheme e Englehart, 2011). Os autores (2011, p. 650) ainda alertam que “a robustez do controle mioelétrico frente a variações nos sinais musculares ainda é um dos maiores desafios para sua aplicação clínica generalizada”.

Em suma, as estratégias de controle mioelétrico têm evoluído de modelos simples para sistemas altamente inteligentes, combinando sensores, algoritmos e modelagem biomecânica. A integração dessas estratégias com tecnologias emergentes, como inteligência artificial e sensores vestíveis, abre novos caminhos para a personalização e eficácia do controle motor assistido pela EMG (Farina *et al.*, 2014).

## **2.4 Pipeline de Reconhecimento de Padrões em sEMG**

O reconhecimento de padrões em sinais de eletromiografia de superfície é uma das abordagens mais avançadas no campo do controle mioelétrico, especialmente na criação de próteses ativas e interfaces homem-máquina (Phinyomark *et al.*, 2013). Para que o sistema funcione corretamente, é necessário que o sinal sEMG bruto passe por um processo estruturado e sequencial, chamado de *pipeline* de reconhecimento de padrões. Este *pipeline* compreende várias etapas fundamentais, incluindo aquisição do

señal, filtragem, janelamento, extração de características, normalização, redução de dimensionalidade, classificação e, por fim, pós-processamento ou decisão de controle (Farina *et al.*, 2014). De forma que a sequência do pipeline pode ser adaptada para as necessidades específicas de cada modelo de acordo com a estratégia adotada, conforme visto na Figura 1.



A primeira etapa do pipeline é a aquisição do sinal, na qual os sinais mioelétricos são captados por eletrodos de superfície posicionados sobre a pele. Essa etapa exige cuidados rigorosos com a colocação dos eletrodos, preparo da pele e escolha adequada da taxa de amostragem (De Luca, 1997; Farina *et al.*, 2014). Segundo De Luca (2002), a precisão na aquisição influencia diretamente a qualidade das informações extraídas do sinal e, portanto, a eficácia do sistema de reconhecimento.

Em seguida, o sinal passa pela filtragem, que visa a remoção de ruídos e artefatos, como interferências da rede elétrica, ruídos fisiológicos e o movimento dos eletrodos. Farina *et al.* (2014) destacam que a remoção de interferências, como o ruído de rede elétrica e o movimento dos eletrodos, é essencial para garantir a integridade dos dados. Após a filtragem, o sinal é submetido à segmentação, uma etapa crucial no processamento de sinais mioelétricos. Essa fase consiste em dividir o sinal contínuo em janelas de tempo, que são analisadas individualmente para extrair informações relevantes, como características estatísticas e espectrais.

A extração de características é considerada uma das etapas mais críticas do pipeline. Nessa fase, o sinal EMG é analisado para obter medidas estatísticas, temporais ou espectrais que representem a atividade muscular de forma discriminativa. Segundo Englehart e Hudgins (2003), a escolha adequada das características

determina a separabilidade entre os padrões motores e influencia diretamente o desempenho do classificador.

Com as características extraídas, pode-se aplicar a normalização, uma técnica estatística amplamente empregada para padronizar os dados e mitigar variações entre indivíduos, ruídos e mudanças no posicionamento dos eletrodos. A normalização pode ser realizada antes ou após a extração de características, dependendo do paradigma de aprendizado de máquina utilizado (HUANG et al., 2023).

Em seguida, pode-se aplicar técnicas de redução de dimensionalidade, como Análise de Componentes Principais (PCA), que visa diminuir a complexidade computacional e aumentar a generalização do modelo (Phinyomark et al., 2012). Segundo Englehart e Hudgins (2003), essa etapa é especialmente útil quando se trabalha com múltiplos canais de EMG e grandes conjuntos de dados.

Na sequência, a fase de classificação utiliza algoritmos supervisionados para atribuir os padrões extraídos a comandos específicos. Entre os classificadores mais utilizados estão LDA, SVM e redes neurais como a CNN. De acordo com Scheme e Englehart (2011), a precisão da classificação depende tanto do algoritmo quanto da qualidade do conjunto de treinamento e da consistência dos sinais.

Para tanto, o sistema pode incluir uma etapa de pós-processamento, como filtragem temporal ou decisões baseadas em janelas móveis, para suavizar as saídas do classificador e evitar respostas erráticas. Essa fase busca garantir estabilidade e confiabilidade ao controle mioelétrico em tempo real (Farina et al., 2014; Scheme; Englehart, 2011).

## **2.5 Filtragem**

O pré-processamento do sinal eletromiográfico é uma etapa essencial para garantir a integridade e confiabilidade das informações extraídas do sinal mioelétrico. Antes que os dados possam ser utilizados em sistemas de controle mioelétrico, é necessário reduzir interferências, atenuar ruídos e padronizar os sinais. Dentre as técnicas mais comuns de pré-processamento destacam-se a filtragem e a normalização (Phinyomark et al., 2012; Farina et al., 2014).

A filtragem do sinal sEMG é empregada para eliminar componentes de ruído provenientes de diferentes fontes, como interferência da rede elétrica, tipicamente em 50 ou 60 Hz, movimento dos eletrodos e ruídos fisiológicos. A filtragem geralmente é

feita por meio de filtros passa-banda, que preservam a faixa de frequência relevante do sinal (De Luca, 1997; Farina *et al.*, 2014). Ainda segundo De Luca (2002), a maioria dos sinais EMG de superfície contém informações úteis entre 20 e 450 Hz, sendo essa a faixa recomendada para a aplicação de filtros passa-banda.

Dessa forma, a aplicação adequada de filtros é crucial para evitar a distorção dos sinais, pois um processamento incorreto pode eliminar componentes importantes ou introduzir atrasos indesejáveis na análise. Como salientam Mesin *et al.* (2004), a precisão da filtragem impacta diretamente a confiabilidade das análises subsequentes, especialmente em aplicações em tempo real.

## **2.6 Segmentação do Sinal: Janelas e Sobreposição**

A segmentação do sinal é uma etapa fundamental no processamento de sinais mioelétricos, especialmente em aplicações de reconhecimento de padrões para controle de próteses, exoesqueletos e interfaces homem-máquina (Hudgins *et al.*, 1993). Essa fase consiste em dividir o sinal contínuo em janelas de tempo, que são analisadas individualmente para extrair informações relevantes, como características estatísticas e espectrais (Phinyomark *et al.*, 2013).

Segundo Englehart e Hudgins (2003), a maioria dos estudos utiliza janelas com duração entre 100 e 250 milissegundos, pois esse intervalo oferece um bom equilíbrio entre acurácia e tempo de resposta, ou seja, a escolha do tamanho da janela impacta diretamente a precisão e a responsividade do sistema. Janelas muito curtas podem não conter informação suficiente para uma boa extração de características, enquanto janelas muito longas podem atrasar a resposta do sistema.

Além do tamanho da janela, é comum utilizar a técnica de sobreposição, em que uma parte da janela atual se repete na janela seguinte. Isso permite um fluxo contínuo de análise e reduz o risco de perda de informações relevantes que ocorrem nas bordas das janelas (Phinyomark *et al.*, 2013). Scheme e Englehart (2011) destacam que uma sobreposição de 25% a 75% é amplamente adotada para garantir transições suaves e melhorar a robustez do reconhecimento de padrões em tempo real.

A segmentação com sobreposição também aumenta a resolução temporal do sistema, permitindo que ele responda de forma mais sensível a variações rápidas na atividade muscular. No entanto, isso gera um maior volume de dados, exigindo mais poder computacional e memória. Por isso, é necessário balancear a taxa de

sobreposição com a capacidade de processamento do sistema, especialmente em aplicações embarcadas ou portáteis (Phinyomark *et al.*, 2013; Hudgins *et al.*, 1993).

O tipo de janela utilizada também pode influenciar a qualidade da segmentação, sobretudo quando as características extraídas envolvem transformadas no domínio da frequência. Conforme Merletti e Parker (2010), a forma da janela afeta a atenuação de bordas e a suavidade dos dados segmentados, o que pode ser crítico na análise espectral.

Portanto, o uso adequado de janelas temporais com sobreposição é uma técnica essencial para garantir uma análise eficiente, precisa e contínua dos sinais mioelétricos. Essa etapa sustenta a extração de características de qualidade e, por consequência, melhora significativamente o desempenho de sistemas baseados em RP e controle motor assistido por EMG (Phinyomark *et al.*, 2013; Hudgins *et al.*, 1993).

## 2.7 Normalização

Após a atenuação de ruídos e interferências através da filtragem, o sinal sEMG está mais limpo em seu conteúdo de frequência. No entanto, a sua amplitude ainda apresenta uma alta variabilidade, que pode ocorrer entre diferentes indivíduos, músculos ou até mesmo ao longo de uma única sessão de coleta. Para mitigar esse efeito e padronizar a escala dos dados antes da extração de características, aplica-se a etapa de normalização.

Uma das técnicas mais comuns para este fim é a Z-Score, técnica estatística amplamente empregada no pré-processamento de sEMG, com o objetivo de padronizar os dados para que apresentem média zero ( $\mu$ ) e desvio-padrão ( $\sigma$ ) unitário:

$$Z = \frac{(x - \mu)}{\sigma}$$

Essa abordagem reduz o impacto de variações inter e intrausuário, ruídos provenientes de alterações fisiológicas e mudanças no posicionamento dos eletrodos, tornando o sinal mais consistente para etapas posteriores de extração de características e classificação (HUANG *et al.*, 2023; LIU *et al.*, 2024).

Em contextos de controle mioelétrico, a normalização Z-Score tem se mostrado especialmente eficaz para minimizar degradações de desempenho provocadas por deslocamentos de eletrodos ou variações de amplitude do sinal (TANAKA; NAMBU;

WADA, 2025). Essa evidência reforça a relevância da normalização Z-Score como etapa crítica para aumentar a robustez de sistemas baseados em sEMG, sobretudo em aplicações que exigem operação em tempo real e confiabilidade em diferentes condições operacionais.

## 2.8 Extração de Características para Modelos

A etapa de extração de características é uma das mais determinantes no desempenho de sistemas de RP baseados em sEMG, especialmente quando se utiliza modelos clássicos de classificação, como LDA e SVM (Phinyomark *et al.*, 2013; Englehart; Hudgins, 2003).

Segundo Englehart e Hudgins (2003), as características extraídas devem ser suficientemente representativas da atividade muscular, permitindo a separação confiável entre diferentes gestos, comandos ou contrações. Para modelos clássicos, é fundamental que essas características sejam estatisticamente consistentes, de baixa dimensionalidade e computacionalmente leves, para facilitar o treinamento e a inferência em tempo real. As características extraídas podem ser agrupadas em dois domínios principais.

### 2.8.1 Domínio Temporal

As características no domínio do tempo são amplamente utilizadas por sua simplicidade computacional e boa capacidade discriminativa, especialmente em aplicações de controle mioelétrico em tempo real (Phinyomark *et al.*, 2013). Entre as mais conhecidas estão:

- MAV (*Mean Absolute Value*) – Representa a média dos valores absolutos da janela. É uma característica simples e eficaz, amplamente utilizada em análise de sinais EMG para capturar a amplitude média da atividade muscular (Phinyomark *et al.*, 2013; Hudgins *et al.*, 1993).
- RMS (*Root Mean Square*) – Relaciona-se com a energia do sinal na janela. Segundo Phinyomark *et al.* (2012), “o RMS é uma das características mais robustas e amplamente aplicadas no controle mioelétrico por sua relação direta com a força de contração muscular”.

- ZC (*Zero Crossings*) – Conta quantas vezes o sinal cruza o zero. Essa característica está relacionada à frequência do sinal e é útil para capturar a informação espectral da atividade muscular (Phinyomark *et al.*, 2013; Hudgins *et al.*, 1993).
- WL (*Waveform Length*) – Representa a soma das diferenças absolutas entre amostras consecutivas do sinal EMG. Essa característica está relacionada à complexidade e frequência do sinal, sendo útil para capturar variações rápidas na atividade muscular (Phinyomark *et al.*, 2013; Hudgins *et al.*, 1993).
- SSC (*Slope Sign Changes*) – Indica as mudanças na inclinação do sinal, relacionadas à curvatura da onda EMG. Essa característica é útil para detectar padrões de ativação muscular e transições rápidas no sinal (Phinyomark *et al.*, 2013; Hudgins *et al.*, 1993).

### 2.8.2 Domínio da Frequência

Para identificar padrões mais complexos, características no domínio da frequência podem ser aplicadas, especialmente com auxílio da Transformada Rápida de Fourier (FFT) ou Wavelet. Essas técnicas permitem analisar a distribuição espectral dos sinais EMG, fornecendo informações relevantes para a discriminação de movimentos musculares (Phinyomark *et al.*, 2013; Farina *et al.*, 2014). Entre elas então:

- MNF (*Mean Frequency*) – Frequência média do espectro de potência.
- MDF (*Median Frequency*) – Frequência que divide o espectro em duas metades com igual energia.
- Potência Espectral Total – Soma da densidade espectral de potência em determinada faixa.

No entanto, segundo Scheme e Englehart (2011), as características no domínio da frequência são mais sensíveis ao ruído e exigem maior capacidade computacional, o que pode limitar seu uso em sistemas embarcados.

## 2.9 Paradigmas de Classificação para Sinais Mioelétricos

O avanço das tecnologias de aquisição e processamento de sinais



eletromiográficos de superfície tem impulsionado o desenvolvimento de diversos paradigmas de classificação, especialmente no contexto de RP para controle mioelétrico (Farina *et al.*, 2014; Phinyomark *et al.*, 2013). Esses paradigmas representam os modelos matemáticos e computacionais usados para interpretar os padrões de atividade muscular e associá-los a comandos funcionais (Scheme; Englehart, 2011).

Segundo Englehart e Hudgins (2003), a escolha do paradigma de classificação é determinante para a acurácia, robustez e tempo de resposta de um sistema de controle mioelétrico funcional. Os paradigmas de classificação mais utilizados podem ser agrupados em três categorias principais: modelos lineares, modelos não lineares e modelos baseados em aprendizado profundo.

**Tabela 1 - Comparação entre paradigmas de classificação para sEMG**

<b>Paradigma</b>	<b>Principais Características</b>	<b>Vantagens</b>	<b>Limitações</b>	<b>Hiperparâmetros Relevantes</b>	<b>Referência</b>
<b>LDA</b>	Projeta dados em subespaço linear maximizando a separação entre classes.	Baixo custo computacional; Fácil implementação; Bom desempenho para dados linearmente separáveis.	Desempenho reduzido em dados não lineares; Sensível a outliers.	Não possui hiperparâmetros de ajuste significativos; depende de pré-processamento adequado.	HUANG <i>et al.</i> , 2023
<b>SVM</b>	Encontra hiperplano ótimo que maximiza a margem entre classes, podendo usar funções kernel para não linearidade.	Alta capacidade de generalização; Eficaz com conjuntos de dados menores.	Ajuste sensível de hiperparâmetros; Tempo de treino elevado para grandes bases.	Tipo de kernel (linear, RBF, polinomial), parâmetro C, $\gamma$ (gamma) para kernels não lineares.	LIU <i>et al.</i> , 2024
<b>CNN</b>	Redes neurais profundas compostas por camadas convolucionais, pooling e totalmente conectadas.	Capacidade de extrair automaticamente características complexas; Excelente desempenho em padrões não lineares.	Alta demanda computacional; Necessidade de grandes conjuntos de dados; Treinamento mais demorado.	Nº de filtros, tamanho do kernel, função de ativação (ReLU, etc.), taxa de aprendizado, batch size.	Atzori, Cognolato; Müller, 2016

Fonte: Adaptado de Huang *et al.* (2023), Liu *et al.* (2024) e Atzori, Cognolato; Müller, 2016.

### 2.9.1 Classificadores Clássicos

Os modelos clássicos de aprendizado de máquina têm sido a base do controle mioelétrico por décadas, oferecendo um bom balanço entre performance e eficiência computacional.

A Análise Discriminante Linear é um dos classificadores mais utilizados na área, frequentemente servindo como um padrão de referência devido à sua simplicidade e baixo custo computacional. Esse paradigma busca encontrar uma projeção linear dos dados que maximize a separação entre as médias das diferentes classes, ao mesmo tempo que minimize a variância dentro de cada classe. Sua principal vantagem é a eficiência, o que o torna ideal para aplicações em tempo real e sistemas embarcados (Oskoei; Hu, 2008). Contudo, sua principal limitação é a premissa de que as classes são linearmente separáveis, o que pode resultar em menor acurácia para tarefas mais complexas, já que a sEMG registra alta sobreposição, dependendo dos padrões musculares.

Para superar a limitação da linearidade, a Máquina de Vetores de Suporte se estabeleceu como uma alternativa poderosa. O SVM busca encontrar um hiperplano ótimo que não apenas separe as classes, mas que o faça com a máxima margem possível, o que lhe confere uma alta capacidade de generalização e robustez a ruídos (Oskoei; Hu, 2008).

A grande vantagem do SVM sobre modelos lineares é sua capacidade de resolver problemas onde os dados não são linearmente separáveis. Isso é alcançado através do uso de funções de kernel, que projetam os dados de entrada para um espaço de características de maior dimensão. A intenção é que, nesse novo espaço, os dados que antes estavam entrelaçados se tornem linearmente separáveis por um hiperplano. Essa técnica, conhecida como "kernel trick", permite que o SVM crie fronteiras de decisão não-lineares e complexas no espaço original, adaptando-se melhor à distribuição real dos dados (OSKOEI; HU, 2008).

Adicionalmente, por ser inerentemente um classificador binário, o SVM requer uma estratégia para lidar com problemas de múltiplas classes, como a classificação de vários movimentos. A abordagem Um-Contra-Um, utilizada neste trabalho, consiste em treinar um classificador SVM para cada par de classes existentes. Durante a predição, cada um desses classificadores "vota" em uma das duas classes que ele foi treinado para distinguir, e a classe que recebe o maior número de votos é a escolhida como a

predição final. Apesar de sua alta performance, o SVM exige um custo computacional de treinamento mais elevado e um cuidadoso processo de otimização de seus hiperparâmetros, como C, gamma e o tipo de kernel.

### 2.9.2 Paradigma de Aprendizado Profundo

Em contraste com os modelos clássicos, o aprendizado profundo, representado principalmente pelas Redes Neurais Convolucionais, propõe uma mudança de paradigma: da engenharia de características para o aprendizado de características. Em vez de depender de um conjunto de features projetado manualmente, as CNNs empregam uma abordagem de ponta a ponta (end-to-end), aprendendo a extrair as representações mais discriminativas diretamente do sinal sEMG bruto (Atzori, Cognolato; Müller, 2016).

A arquitetura de uma CNN, com suas camadas convolucionais e de pooling, é otimizada para aprender padrões hierárquicos em dados sequenciais, como o sEMG. As primeiras camadas aprendem a identificar características de baixo nível, que são combinadas em camadas mais profundas para formar padrões complexos e abstratos, específicos para cada movimento. Essa capacidade de aprendizado automático tem o potencial de gerar modelos mais robustos à variabilidade do sinal. Contudo, as CNNs possuem desvantagens significativas: exigem um alto poder computacional para treinamento e, crucialmente, necessitam de grandes volumes de dados rotulados para atingir seu pleno potencial, uma limitação importante na área de sEMG, conforme destacado por Farina et al. (2014) e Côté-Allard et al. (2017).

## 2.10 Desafios e Limitações Atuais no Controle Mioelétrico

O processamento e a interpretação de sinais mioelétricos de superfície enfrentam diversos desafios que limitam a plena eficácia e aplicabilidade das tecnologias atuais em controle mioelétrico, reabilitação e análise funcional. Entre os principais obstáculos destacam-se a variabilidade fisiológica, o ruído intrínseco do sinal, a necessidade de sistemas responsivos em tempo real e a adaptação a diferentes usuários e condições clínicas (Farina *et al.*, 2014; Scheme & Englehart, 2011).

Conforme salientam Scheme e Englehart (2011), a variabilidade do sinal sEMG, causada por fatores como fadiga muscular, deslizamento dos eletrodos e diferenças anatômicas entre indivíduos, representa um dos maiores desafios para o desenvolvimento de classificadores robustos. Essa variabilidade impacta diretamente na estabilidade e na acurácia dos sistemas de reconhecimento de padrões, exigindo estratégias avançadas de pré-processamento, extração de características e aprendizado de máquina (Farina *et al.*, 2014; Scheme & Englehart, 2011).

Além disso, Farina *et al.* (2014) destacam que a escassez de bases de dados amplas e padronizadas para treinamento e validação limita o avanço das técnicas, principalmente aquelas baseadas em aprendizado profundo, que demandam grande quantidade de dados rotulados. Essa limitação justifica a necessidade de estudos que não apenas desenvolvam novos métodos, mas também promovam a construção e disponibilização de datasets representativos.

Outro desafio é a implementação de sistemas mioelétricos que aliem alta precisão com baixa latência e consumo reduzido de energia, especialmente para dispositivos portáteis e aplicações clínicas. Segundo Phinyomark *et al.* (2013), a otimização do pipeline de processamento, desde o pré-processamento até a classificação, é essencial para garantir a viabilidade prática dos sistemas em ambientes reais.

### 3 METODOLOGIA

#### 3.1 Aquisição de Dados e Protocolo Experimental

##### 3.1.1 Participantes

O desenvolvimento do projeto se deu com a participação de cinco voluntários saudáveis com idades entre 24 e 30 anos, todos destros e sem quaisquer disfunções motoras, destes quatro eram do do sexo masculino e um do sexo feminino. Todas as coletas foram realizadas *in-loco* no Laboratório de Engenharia Biomédica (BioLab) da Universidade Federal de Uberlândia (UFU) com o consentimento prévio de todos os participantes. Este trabalho foi aprovado pelo Comitê de Ética em Pesquisa da UFU - Parecer 6.270.389.

##### 3.1.2 Aquisição de dados

Para coleta de dados, foi utilizado o Eletromiógrafo MyosystemBr1-P84 (DataHominis Tec Ltda), com uma taxa de amostragem definida em 2 kHz para três canais de medição. Foram empregados eletrodos ativos em configuração diferencial, selecionados por suas vantagens intrínsecas na melhoria da qualidade do sinal. Por possuírem um pré-amplificador integrado, configurados para um ganho de 20x, esses eletrodos aumentam a relação sinal-ruído diretamente na fonte, oferecendo alta rejeição a interferências de modo comum, como o ruído de 60 Hz. Além disso, por serem eletrodos do tipo seco, eles dispensam a necessidade de gel condutor e abrasão da pele, tornando o processo de coleta mais rápido e confortável para o voluntário.


##### 3.1.3 Posicionamento dos Eletrodos

Através de buscas na literatura foi possível identificar referências que propõem protocolos para a padronização do posicionamento superficial dos eletrodos, visando identificar a altura ideal no plano transversal do antebraço (Zipp, 1982). O procedimento seguido, se dá com a medição do comprimento do antebraço a partir de duas linhas de referência: a primeira, na face interna, traçada do epicôndilo medial do úmero (epitróclea) até o sulco distal do punho e a segunda, na face externa, do

epicôndilo lateral do úmero até o ponto médio entre os processos estiloides da ulna e do rádio. Em seguida, foi demarcado um ponto em cada uma dessas linhas correspondentes a 25% de seu comprimento total, medido a partir do cotovelo, no qual, foram interligados formando uma linha circunferencial ao redor do antebraço, sobre a qual os eletrodos foram posicionados.

Uma vez definida a linha circunferencial no plano transversal do antebraço, foram selecionadas três regiões musculares para o posicionamento dos eletrodos. Com auxílio da palpação, a escolha visou abranger músculos-chave para os movimentos dos dedos, incluindo tanto agonistas (flexores) quanto antagonistas (extensores). Dessa forma, os eletrodos foram posicionados sobre as superfícies dos músculos Flexor Superficial dos Dedos (E1), Flexor Ulnar do Carpo (E2) e Extensor dos Dedos (E3) conforme a Figura 2.

**Figura 2 - Visualização, em corte transversal, do posicionamento dos eletrodos no antebraço**




Fonte: Elaborado pelo autor (2025).

### 3.1.4 Procedimento experimental

Foram selecionados para compor o protocolo experimental sete tarefas motoras distintas por representarem um conjunto de movimentos finos e funcionalmente relevantes dos dedos. As tarefas incluíram a flexão individual do polegar, indicador, médio, anelar e mínimo, o qual permitiu uma análise da ativação isolada de cada dígito. Adicionalmente, foram incluídos dois movimentos funcionais essenciais para atividades de vida diária, a pinça, composto pela oposição do polegar e indicador, e o tripod, composto pela oposição do polegar aos dedos indicador e médio Figura 3.

**Figura 3 - Ilustração das tarefas definidas para o protocolo experimental.**



Fonte: Elaborado pelo autor (2025).

Logo, para investigar o impacto da complexidade da tarefa no desempenho dos classificadores, foi criado um segundo cenário de análise, mais simples, utilizando um subconjunto correspondente apenas aos movimentos de flexão individual dos cinco dedos. A criação deste subconjunto teve como objetivo remover os movimentos funcionalmente mais complexos (Pinça e Tripod), que possuem maior potencial de sobreposição de padrões, permitindo assim uma análise de desempenho em uma tarefa de menor dificuldade.

Para garantir a consistência e a repetibilidade das contrações entre os participantes e ao longo das diferentes sessões, a execução dos movimentos foi padronizada. Para isso, utilizou-se uma pequena bola de borracha, onde, durante a fase de contração de cada tarefa, os voluntários foram instruídos a realizar a preensão do objeto, o que permitiu padronizar a postura da mão e o nível de força isométrica aplicada. Nos intervalos de repouso, a mão permanecia relaxada, em posição de repouso e posicionada sobre a bola, garantindo uma posição inicial consistente antes do início de cada nova repetição.

As sessões foram conduzidas com os voluntários confortavelmente sentados, com o braço dominante, direito, posicionado sobre uma mesa e o cotovelo mantido em um ângulo de aproximadamente  $140^\circ$ . Cada uma das sete tarefas foi dividida em seis blocos de dez repetições do mesmo movimento, de forma que, cada repetição perdurava por três segundos seguidos por um intervalo de repouso de três segundos. A temporização de cada tarefa foi controlada por uma sinalização audiovisual apresentada em um monitor, sincronizada com a coleta através de um trigger, gerado por um canal auxiliar do eletromiógrafo, que envia pulsos simultâneos para inicializar tanto ao software de coleta quando o vídeo com feedback audiovisual.

A fim de mitigar possíveis efeitos de fadiga nos voluntários, a ordem de execução das tarefas foi randomizada para cada participante e um intervalo de repouso superior a 3 minutos era concedido entre a conclusão de uma tarefa e o início da próxima. A sessão de coleta completa, incluindo preparação e instruções, teve duração aproximada de 110 minutos por voluntário.

### **3.2 Pré-processamento dos Dados**


Finalizada a etapa de aquisição, os dados brutos foram submetidos a uma etapa de pré-processamento para atenuação de ruídos e artefatos, e estruturação dos dados para aplicação nos modelos de aprendizado de máquina. Inicialmente, foi aplicado um filtro passa-banda Butterworth de 4ª ordem, com frequências de corte em 20 Hz e 500 Hz, com o objetivo de remover o nível DC e os artefatos de movimento de baixa frequência, ao mesmo tempo que preserva a faixa espectral onde se concentra a maior parte da potência do sinal sEMG. Em seguida, para atenuar a interferência da rede elétrica, aplicou-se um filtro Notch de 4ª ordem, configurado para frequência fundamental de 60 Hz e seus harmônicos em 120 Hz e 180 Hz.

Todo o pipeline de processamento, desde a filtragem do sinal até o treinamento e avaliação dos modelos, foi implementado na linguagem de programação Python (v3.10.11), utilizando bibliotecas científicas como SciPy, NumPy, sklearn e tensorflow no ambiente de desenvolvimento Visual Studio 2024. Para garantir a reprodutibilidade e contextualizar as métricas de desempenho computacional, todos os experimentos foram executados em uma única máquina com a seguinte configuração de hardware: processador Intel® Core™ i7-10750H de 2.60GHz, 8,00 GB de memória RAM e uma



unidade de processamento gráfico (GPU) com 4 GB de memória dedicada.

**Figura 4 - Visualização de um bloco de 10 contrações do sinal filtrado e espectro de frequência**




Fonte: Elaborado pelo autor (2025).

Para extração dos intervalos de interesse correspondentes a cada ativação muscular, utilizou-se a sincronização entre a coleta e o sistema de feedback audiovisual, viabilizada pelo trigger, que atuou como um marcador temporal preciso, indicando o instante exato em que o comando para iniciar ou cessar cada contração foi emitido. A utilização deste marcador foi crucial para automatizar a extração dos intervalos de interesse de forma consistente e replicável em todo o conjunto de dados.

A partir de cada marcador temporal extraído que sinalizava o início de uma tarefa, foi considerado um offset de 200 ms para iniciar a coleta da janela de interesse e extraída uma janela de 3,2 segundos de duração. Esta janela foi definida para abranger não apenas os 3 segundos da contração muscular, mas também um intervalo de 200 ms segundos depois do estímulo. A inclusão do *offset* e do intervalo pós-estímulo, por sua vez, foi implementada para compensar o tempo de reação visuo-motor. Estudos que analisam respostas musculares do membro superior a estímulos visuais reportam que a atividade muscular voluntária se inicia aproximadamente entre 200 a 300 ms após o estímulo (GU *et al.*, 2019). Esses deslocamentos e janelas, portanto, garante que seja reduzida a carga de amostras quando o voluntário está em estado de repouso e a fase final de desativação muscular

seja registrada ao máximo, assegurando que cada janela de interesse contivesse significativa parte do evento motor.

**Figura 5 - Visualização da extração de intervalos de interesse do sinal**




Fonte: Elaborado pelo autor (2025).

Concluída a seleção dos intervalos de interesse, cada segmento de contração foi submetido à técnica de janelamento sobreposto para a subsequente extração de características, com a utilização de janelas com duração de 200 ms e uma sobreposição de 80%, o que corresponde a um incremento de 40 ms entre janelas consecutivas. A escolha desse tamanho de janela se justifica pela quantidade de informação do sinal, que contém informação suficiente para extração de informações úteis, ao mesmo tempo, esta duração respeita a restrição de latência total inferior a 300 ms, que é crucial para que o controle da prótese seja percebido como intuitivo pelo usuário. Já à utilização da sobreposição, por sua vez, é uma técnica recomendada para aumentar a velocidade e a frequência das respostas do sistema de controle em tempo real, sem sacrificar a precisão da classificação. (Oskoei; Hu, 2008).

Este processo de janelamento resultou em um total de 33.572 e 23.980 janelas por voluntário para os cenários de sete e cinco tarefas, respectivamente. Cada uma dessas janelas constitui uma amostra individual para a etapa subsequente de extração de características e classificação.

**Figura 6 - Demonstração da aplicação de janela deslizante no sinal**



Fonte: Elaborado pelo autor (2025).

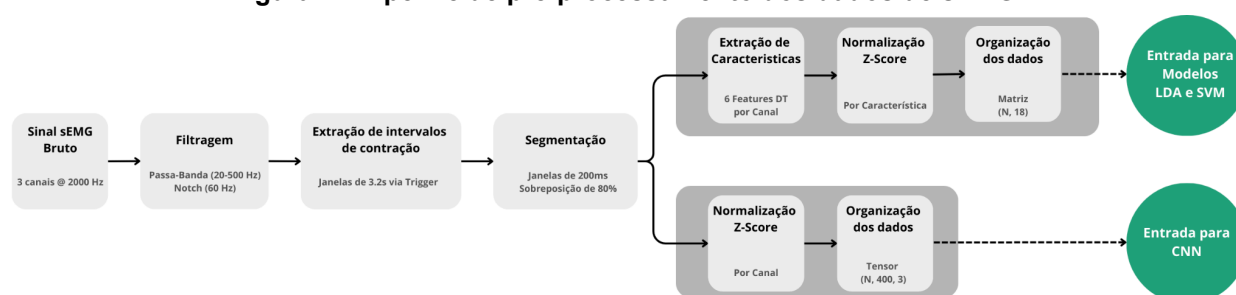
Para os modelos clássicos como LDA e SVM, foram extraídas seis características do domínio do tempo de cada janela, sendo elas, Valor Médio Quadrático (RMS), Valor Médio Absoluto (MAV), Comprimento de Onda (WL), Variância (VAR), Cruzamentos por Zero (ZC) e Mudança de Sinal da Inclinação (SSC). Considerando os três canais de aquisição, a concatenação dessas características resultou em um vetor final de 18 dimensões (6 características x 3 canais) para cada amostra, ou seja, para cada janela de tempo individual extraída. A seleção do conjunto teve como base a combinação de um padrão de referência consolidado na literatura, MAV, WL, ZC e SSC proposto por Hudgins (1992) e é referência na área e se justifica pelo seu comprovado equilíbrio entre uma alta taxa de acurácia, robustez e uma baixa complexidade computacional, ideal para sistemas de controle. Buscando criar um vetor de características ainda mais descritivo da atividade muscular, foram adicionadas as características de RMS, por ser um dos mais poderosos e comuns descritores da amplitude do sinal sEMG, e VAR outra medida da potência do sinal, no qual a combinação final de todas as seis características apresentou um ganho significativo na acurácia da classificação, justificando sua utilização no presente trabalho.

Para reduzir a variabilidade de amplitude do sinal entre os voluntários e padronizar a escala dos dados de entrada para os classificadores, foi aplicada a técnica de normalização Z-score. Este procedimento foi realizado de forma intra-sujeito, ou seja, os parâmetros de normalização, média e desvio padrão foram calculados exclusivamente a partir do conjunto de treino de cada participante, vale

ressaltar que a implementação da normalização foi ligeiramente diferente entre os paradigmas de aprendizado de máquina.

Nos modelos clássicos, a normalização foi aplicada de forma individual por característica extraída, com a média e o desvio padrão calculados de forma independente para cada uma das 18 colunas do vetor de características, com a utilização apenas dos dados de treinamento, porém com a normalização realizada em ambos os conjuntos de dados. Para o modelo da CNN, a normalização foi aplicada de forma análoga, mas diretamente por canal. A média e o desvio padrão foram calculados para cada um dos três canais de sEMG, utilizando apenas os dados do conjunto de treinamento, o que preparou o sinal para ser processado pela arquitetura da rede.

**Figura 7 - Pipeline de pré-processamento dos dados de sEMG.**



Fonte: Elaborado pelo autor (2025).

### 3.3 Processamento dos Dados

Concluída a etapa de pré-processamento, os dados de cada voluntário foram organizados em duas estruturas distintas, cada uma otimizada para o paradigma de aprendizado de máquina correspondente. Essa preparação resultou nos dois conjuntos de dados descritos abaixo:

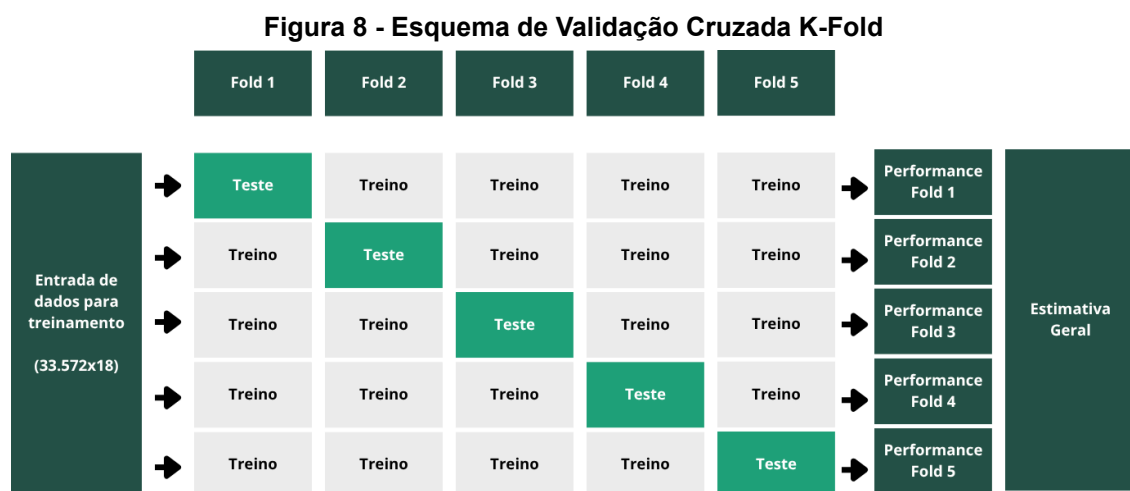
- Conjunto 1: Destinado aos modelos clássicos LDA e SVM, este conjunto foi estruturado como uma matriz bidimensional. Cada linha da matriz representa um segmento de sinal, janela de tempo, e as 18 colunas correspondem ao vetor de características extraídas (6 características x 3 canais).
- Conjunto 2: Para o modelo de CNN, os dados foram organizados como um tensor tridimensional com o formato (N,400,3). Neste formato, N representa o número total de segmentos de sinal, 400 são as amostras de dados na janela temporal de 200 ms, e 3 são os canais de sEMG. Essa estrutura foi escolhida

para preservar a natureza espaço-temporal do sinal, o que é fundamental para que as camadas convolucionais da CNN aprendam as características relevantes diretamente dos dados brutos.

É importante ressaltar que ambos os conjuntos de dados foram gerados em duas versões distintas: uma contendo os dados das sete classes de movimento e outra apenas com os dados do subconjunto de cinco classes. Essa abordagem permitiu a análise comparativa do desempenho dos modelos em tarefas de complexidade variada.

### 3.3.1 Análise Discriminante Linear (LDA)

Para a avaliação do modelo de LDA, foi empregada a técnica de validação cruzada de 5-Folds, já que apresenta uma estimativa mais robusta e imparcial do desempenho de generalização do modelo, de forma que o conjunto de dados de cada participante foi subdividido randomicamente entre 5 subconjuntos, garantindo uma distribuição equilibrada das classes de movimentos entre cada um dos subconjuntos. Dessa forma, foi iterando por cada um dos subgrupos e em cada iteração, 1 fold (20%) era utilizado como conjunto de teste e os 4 restantes (80%) como conjunto de treinamento.



Fonte: Elaborado pelo autor (2025).

Durante cada uma das 5 iterações, foram mensuradas e armazenadas as métricas de desempenho no respectivo fold de testes como a acurácia, tempo de treinamento e a latência média de inferência por amostra. O desempenho final do modelo LDA é, portanto, reportado com a média e desvio padrão dessas métricas,

calculados sobre os resultados de todos os 5 folds. Esta abordagem fornece uma medida mais confiável da performance esperada do modelo em dados não vistos, em comparação com uma única divisão de dados entre treino e teste.

### 3.3.2 *Máquina de Vetores de Suporte (SVM)*

Diferentemente do LDA, o desempenho do SVM é altamente influenciado pela seleção de seus hiperparâmetros, o que permite atingir resultados significativamente maiores. Desta forma, a metodologia para este modelo foi estruturada em duas etapas principais: otimização e avaliação.

A primeira fase foi realizada uma otimização de hiperparâmetros, com objetivo de encontrar os parâmetros que melhor se adequam a cada conjunto de dados. Para isso, foi utilizada a técnica de busca em grade com validação cruzada (GridSearch CV), no qual, foram selecionadas várias combinações de valores para serem testadas, para a faixa do parâmetro C foram definidos os valores [1, 10, 50, 100, 200, 600 e 1000] e para a faixa de gamma [0.01, 0.1, 0.16, 0.5, 1, 5] com o Kernel já definido para o de Função de Base Radial (RBF). Totalizando 42 combinações possíveis que foram testadas 5 vezes cada uma para validação cruzada.

Na segunda fase, foi realizada a avaliação final do modelo já otimizado, de forma que os parâmetros ótimos extraídos no passo anterior foram aplicados ao modelo com a aplicação da mesma metodologia de validação cruzada estratificada de 5 folds utilizada para o LDA. Ademais, as mesmas métricas calculadas no modelo anterior também foram calculadas sobre os resultados de todos os 5 folds, fornecendo uma avaliação completa de sua eficácia e eficiência e garantindo uma comparação mais direta e igualitária.

### 3.3.3 *Rede Neural Convolutacional (CNN)*

Por fim, a CNN foi projetada e implementada com uma arquitetura unidimensional, já que possibilita a análise de sinais de série temporal, como o sEMG. Com o intuito de mitigar o alto custo computacional exigido por padrão em modelos de aprendizado profundo a avaliação do modelo foi realizada com uma única divisão dos dados, de forma que o conjunto de cada voluntário foi particionado randomicamente, com estado aleatório fixo, em 80% para treinamento e 20% para validação.


A estrutura da rede foi definida em três blocos convolucionais empilhados sequencialmente seguidos de um bloco de classificação para a tomada de decisão final. Cada bloco convolucional foi padronizado para executar a seguinte sequência de operações. Primeiramente, o de filtros convolucionais analisa a entrada para extrair padrões temporais relevantes no sinal sEMG, de forma que, a saída desses filtros passa por um processo de normalização que estabiliza e acelera o treinamento da rede. Em seguida, a função de ativação não-linear (ReLU) é aplicada para permitir que o modelo aprenda relações complexas e posteriormente, a etapa de subamostragem (*pooling*) configurada para reduzir a dimensão dos mapas de características pela metade, por fim, a técnica de regularização (*dropout*) com taxa de 0.15, desativando aleatoriamente 15% dos neurônios durante o treinamento com o intuito de mitigar o sobreajuste.

Os três blocos foram configurados com uma estratégia de número crescente de filtros e tamanho de kernel decrescente, permitindo que a rede aprendesse características progressivamente mais complexas:

- Bloco 1: 64 filtros, kernel de tamanho 11.
- Bloco 2: 128 filtros, kernel de tamanho 9.
- Bloco 3: 256 filtros, kernel de tamanho 7.

O bloco de classificação foi responsável por receber os mapas de características extraídas pelas camadas anteriores da rede, convertidos em um único vetor, processado pela camada densa oculta de 128 neurônios responsável pelo aprendizado das combinações finais dos padrões extraídos conforme Figura 9. Neste bloco também foi adicionado um dropout com taxa de 40%. Por fim, a camada de saída composta por 7 neurônios e uma função de ativação softmax, calcula a distribuição de probabilidade sobre as classes de movimento, entregando a predição final do modelo. Já para o cenário de 5 classes, a arquitetura da rede foi mantida idêntica, com a única modificação sendo a camada de saída, que passou a ter 5 neurônios para corresponder ao novo número de classes.

**Figura 9 - Arquitetura proposta para CNN**



Fonte: Elaborado pelo autor (2025).

O modelo foi compilado utilizando o otimizador Adam, capaz de ajustar os pesos da rede de forma adaptativa durante o treinamento para minimizar o erro, com uma taxa de aprendizado inicial de 0.001. Como função de perda foi utilizada a “Categorical cross-entropy”, métrica que quantifica a divergência entre a distribuição de probabilidade prevista e o rótulo verdadeiro.

O treinamento da CNN foi configurado para um máximo de 50 épocas, com um tamanho de lote de 64. A cada época que passa, a rede neural processa todo o conjunto de dados de treinamento em lotes, calcula o erro entre suas previsões e os rótulos verdadeiros e, em seguida, utiliza este erro para ajustar seus pesos e vieses internos. Esse ciclo de aprimoramento contínuo é o que permite que a rede aprenda os padrões dos dados de forma progressiva.

Para garantir a melhor performance e evitar o sobreajuste (overfitting), a performance do modelo foi monitorada continuamente no conjunto de validação. A avaliação final da CNN foi realizada utilizando os melhores pesos do modelo, que foram salvos na época em que a maior acurácia foi alcançada no conjunto de validação. A partir desse modelo otimizado, as métricas de desempenho registradas foram a acurácia no conjunto de validação e a latência média de inferência.

### 3.4 Avaliações Comparativas

Concluídas as etapas de processamento e treinamento, os modelos foram submetidos a uma análise comparativa sistemática para avaliar e quantificar o desempenho de cada abordagem. A avaliação foi conduzida com base em quatro variáveis de comparação distintas.

Primeiro, a acurácia de classificação e a capacidade de generalização dos modelos foram comparadas. A acurácia média de validação e o desvio padrão foram



usados para medir o desempenho geral de cada modelo, enquanto a diferença entre a acurácia de treino e a acurácia de validação serviu para avaliar a capacidade de generalização dos modelos.

Em seguida, a robustez inter-sujeito foi avaliada por meio da variabilidade do desempenho de classificação entre os cinco voluntários. Para isso, o desvio padrão da acurácia de validação de cada modelo foi a métrica utilizada para quantificar a estabilidade de performance entre os participantes.

O impacto do número de classes no comportamento dos modelos foi analisado ao se comparar o desempenho de classificação no cenário completo de sete classes com um subconjunto mais simples de cinco classes.

Por fim, uma análise de custo-benefício computacional foi realizada para contrastar a performance de classificação com a eficiência computacional de cada modelo, utilizando como métricas de comparação o tempo médio de treinamento e a latência média de inferência.

## 4 RESULTADOS

Este capítulo apresenta os resultados obtidos da análise comparativa entre os paradigmas de aprendizado de máquinas LDA, SVM e CNN. De forma que, a organização desta sessão se dá a responder diretamente aos objetivos específicos propostos inicialmente no trabalho, abordando o desempenho geral de classificação, a robustez inter-sujeito, o impacto da complexidade da tarefa e o custo-benefício computacional de cada paradigma.

### 4.1 Desempenho de Classificação e Capacidade de Generalização

Como primeiro objetivo, foi comparado o desempenho de classificação e a capacidade de generalização de cada um dos três paradigmas para o grupo de dados de 7 classes. Os resultados detalhados para cada voluntário e modelo são apresentados nas Tabelas 1, 2 e 3.

Como resultado para o primeiro modelo implementado, LDA, exposto na Tabela 1 mostra que o classificador alcançou uma acurácia média durante a validação de  $75,12\% \pm 6,17\%$ . O desempenho individual entre os participantes chegou a variar de um mínimo de 68,75% (Voluntário 5) a um máximo de 82,74% (Voluntário 1), com uma baixa diferença média entre a acurácia de treino e a de validação em 0,07%.

**Tabela 2 - Desempenho Detalhado do Classificador LDA para 7 Classes**

LDA			
Voluntário	Acurácia Treino	Acurácia Validação	Diferença
1	82,82%	82,74%	0,08%
2	76,64%	76,60%	0,04%
3	78,68%	78,64%	0,04%
4	68,90%	68,88%	0,02%
5	68,92%	68,75%	0,17%
<b>Média <math>\pm</math> DP</b>	<b>75,19% <math>\pm</math> 6,15%</b>	<b>75,12% <math>\pm</math> 6,17%</b>	<b>0,07% <math>\pm</math> 0,06%</b>

Para o modelo de SVM, os resultados são detalhados na Tabela 2. É possível verificar que esse classificador apresentou um desempenho significativamente maior em relação ao LDA, atingindo uma acurácia média de validação de  $88,58\% \pm 5,38\%$ ,

um ganho superior a 13 pontos percentuais em relação ao modelo anterior. A diferença média entre treino e validação foi de 1,44%, um valor ainda baixo que indica uma boa capacidade de generalização quando exposto a dados novos.

**Tabela 3 - Desempenho Detalhado do Classificador SVM para 7 Classes**

SVM			
Voluntário	Acurácia Treino	Acurácia Validação	Diferença
1	95,33%	94,61%	0,72%
2	90,97%	89,23%	1,74%
3	93,28%	91,96%	1,32%
4	88,30%	86,48%	1,82%
5	82,24%	80,64%	1,60%
<b>Média ± DP</b>	90,02% ± 5,08%	88,58% ± 5,38%	1,44% ± 0,45%

O desempenho mais alto entre os três paradigmas foi apresentado pela CNN, exposto na Tabela 4, com uma acurácia média de validação de 96,46% ± 1,31%, apresentando o menor desvio padrão em comparação ao LDA e SVM. Já a diferença média entre as acurácias de treino e validação foi de 2,75%, um pouco acima do apresentado nos modelos clássicos.

**Tabela 4 – Desempenho Detalhado do Classificador CNN para 7 Classes**


CNN			
Voluntário	Acurácia Treino	Acurácia Validação	Diferença
1	99,30%	98,17%	1,13%
2	98,66%	95,50%	3,16%
3	99,40%	97,24%	2,16%
4	99,22%	96,57%	2,65%
5	99,48%	94,82%	4,66%
<b>Média ± DP</b>	99,21% ± 0,32%	96,46% ± 1,31%	2,75% ± 1,30%

Como esperado é visível a hierarquia de performance entre os modelos, Figura 10, conforme aumenta o grau de complexidade do modelo, com o aprendizado profundo alcançando a maior acurácia média de validação (96,46% ± 1,31%), seguido pelo SVM (88,58% ± 5,38%) e pelo LDA (75,12% ± 6,17%). Em relação à capacidade de generalização, observou-se uma tendência inversa, o LDA apresentou a menor diferença média entre treino e validação (0,07%), seguido pelo SVM (1,44%) e pela

CNN (2,75%).

## 4.2 Desempenho Geral e Robustez Inter-sujeito

Para atender ao segundo objetivo específico, foi realizada a análise da variabilidade apresentada pelo modelo entre diferentes voluntários sob as mesmas condições, visando quantificar o quão estável o modelo se apresenta. Com isso, foi avaliado o nível de dispersão da acurácia obtida a partir dos conjuntos de testes entre os cinco participantes considerando o grupo de dados completo para as 7 classes de movimento.



Fonte: Elaborado pelo autor (2025).

A CNN demonstrou ser o modelo mais robusto, com o menor desvio padrão na acurácia de teste em  $\pm 1,31\%$ . Visualmente, na Figura 10, as cinco barras correspondentes à CNN apresentam uma consistência significativa no tamanho das barras, com uma amplitude total de apenas 3,35 pontos percentuais entre o melhor (98,17%) e o pior (94,82%) desempenho individual. Em contrapartida, o LDA mostrou-se o modelo menos robusto, exibindo o maior desvio padrão ( $\pm 6,17\%$ ). Essa alta variabilidade é evidenciada na Figura 9 pela grande discrepância na acurácia entre os voluntários.


Com esses resultados, é quantificado de forma objetiva a consistência de cada modelo, indicando que a performance da CNN foi significativamente menos dependente das características individuais dos participantes em comparação com os modelos clássicos.

### 4.3 Analisar o efeito do número de classes no desempenho dos classificadores

A análise do comportamento dos modelos frente a quantidade de tarefas para quantificação foi realizada em duas partes. Primeiramente, realizou-se um comparativo direto entre as predições realizadas pelos três paradigmas para investigação das possíveis fontes de erro através de matrizes de confusão. Posteriormente, foi quantificado o ganho de performance obtido ao simplificar a classificação para um cenário de cinco classes.


A Figura 11 apresenta as matrizes de confusão normalizadas para o voluntário 3, onde é possível observar que, para o LDA, os erros mais expressivos ocorreram entre as classes 'Pinça' e 'Indicador' (15,17%) e 'Mínimo' e 'Pinça' (13,34%). O SVM, embora com uma taxa de erro geral menor, também apresentou as maiores confusões entre essas mesmas classes funcionalmente similares. Em contraste, a matriz da CNN exibe uma diagonal principal muito mais dominante, com erros de classificação mais baixos e distribuídos, indicando uma maior capacidade de discriminação entre os gestos.

**Figura 11-A - Matriz de Confusão Normalizada Modelo LDA**




Fonte: Elaborado pelo autor (2025).

Figura 11-B - Matriz de Confusão Normalizada Modelo SVM



Fonte: Elaborado pelo autor (2025).

Figura 11-C - Matriz de Confusão Normalizada Modelo CNN




Fonte: Elaborado pelo autor (2025).

Com o intuito de avaliar o impacto da complexidade da tarefa no desempenho

dos classificadores, a performance dos modelos foi comparada entre os dois grupos distintos expostos. A Figura 12 apresenta este comparativo, onde é possível observar um aumento no desempenho de classificação para todos os três modelos quando a complexidade da classificação foi reduzida. A acurácia média do LDA aumentou de 75,12% para 81,94%, de forma similar, o SVM melhorou de 88,58% para 91,48%, e a CNN teve sua performance elevada de 96,46% para 96,95%.

**Figura 12 - Desempenho dos Classificadores entre os grupos de 7 e 5 classes.**



Fonte: Elaborado pelo autor (2025).

A análise quantitativa do ganho de desempenho mostra que dependendo do paradigma o impacto não é significativo a ponto de afetar de forma relevante a acurácia do modelo. O modelo LDA foi o mais beneficiado em termos absolutos, com um aumento de 6,82 pontos percentuais na acurácia média. De forma similar, o SVM apresentou um ganho absoluto de 2,90 pontos percentuais, enquanto a CNN obteve o ganho absoluto menor, de 0,49 pontos percentuais.

Estes dados demonstram uma clara tendência de retornos decrescentes, onde o ganho de performance foi inversamente proporcional à acurácia inicial do modelo. A CNN, que já alcançava um desempenho superior a 96% no cenário mais complexo, possuía uma margem menor para melhoria. Em contrapartida, o LDA, com o menor desempenho inicial, foi o que mais se beneficiou da remoção das classes funcionalmente mais complexas (Pinça e Tripod), que possuem maior potencial de sobreposição de padrões musculares.

#### 4.4 Análise de Custo-Benefício Computacional

Como último objetivo, foi pré-estabelecida a análise do custo-benefício de cada paradigma, através do contraste entre a performance de classificação em relação a eficiência computacional. A Tabela 5 apresenta um resumo desses resultados, utilizando o LDA como modelo de referência para as comparações de tempo.

**Tabela 5 - Resumo Comparativo do Desempenho dos Modelos**

<b>Modelo</b>	<b>Acurácia Média</b>	<b>Tempo Médio de Treinamento</b>	<b>Latência Média de Inferência (ms)</b>
<b>LDA</b>	75,12%	1x	1x
<b>SVM</b>	88,58%	~375x	~1.891x
<b>CNN</b>	96,46%	~120.334x	~146.757x

A análise do tempo de treinamento revela uma diferença significativa, em ordens de magnitude, entre os paradigmas. O LDA, foi o modelo que exigiu o menor custo computacional, servindo como nossa base de comparação. O SVM foi cerca de 375 vezes mais lento que o LDA. A CNN, por sua vez, demandou o maior custo computacional, sendo 120.334 vezes mais lenta que o LDA.

Em relação à latência de inferência por amostra, que impacta diretamente na responsividade do sistema em tempo real, o LDA novamente se mostrou o mais rápido. O tempo médio de inferência do SVM foi cerca de 1.891 vezes maior que o do LDA. A CNN, embora tenha registrado a maior latência, considerando o cenário de processamento com as especificações da máquina listada na metodologia, resultou em uma média de 49,07 ms por janela, e nesse cenário, seu valor permaneceu confortavelmente dentro do limiar de 300 ms, que é considerado aceitável para o controle intuitivo de próteses.



## 5 DISCUSSÃO

Os resultados apresentados acima buscam quantificar o desempenho dos três paradigmas de aprendizado de máquina propostos, fornecendo uma base para a discussão sobre suas respectivas vantagens e desvantagens na classificação de movimentos finos da mão. Os resultados demonstraram uma clara hierarquia de desempenho, com a CNN alcançando a maior acurácia, seguida pelo SVM e pelo LDA. A superioridade do SVM sobre o LDA, em mais de 13 pontos percentuais, sugere que as fronteiras de decisão entre as classes de movimentos estudadas possuem componentes não-lineares. Segundo Oskoei e Hu (2008), que, ao analisarem movimentos mais amplos do membro superior, ou seja, padrões com maior ativação muscular e distinção entre si, observaram uma performance similar entre os dois modelos, inferindo uma separabilidade linear para seu conjunto de dados. Isso indica que a complexidade e a sobreposição de padrões em gestos de alta destreza, como os abordados neste trabalho, beneficiam-se da capacidade do kernel RBF do SVM em modelar relações mais complexas.

A dominância da CNN é ainda mais notável ao se considerar a relativa complexidade das tarefas propostas, já que a classificação de movimentos finos dos dedos, em oposição a gestos mais amplos do punho, apresenta um maior desafio devido à menor amplitude do sinal sEMG e à alta sobreposição da atividade muscular, visto que músculos como o flexor e o extensor dos dedos atuam de forma coordenada para as múltiplas tarefas propostas no protocolo experimental. A acurácia de 96,46% para 7 classes se alinha com resultados da literatura para um número similar de gestos, como os ~97.9% reportados por Côté-Allard *et al.* (2016), além disso este alto desempenho entra em conformidade com a observação de Atzori *et al.* (2016), que afirmam que acurácias acima de 90% são de fato esperadas e comuns em estudos que, como esse, se concentram em um número de classes inferior a dez.

Outro aspecto relevante deste estudo é o uso de um sistema de aquisição de baixa resolução espacial, com apenas três canais de sEMG, de forma que a configuração proposta contrasta com a maioria dos trabalhos de referência, que empregam um número maior de eletrodos, como os oito canais no estudo de Côté-Allard *et al.* (2016) ou os doze canais em Zhang *et al.* (2013). A literatura, como a revisão de Oskoei e Hu (2007), sugere que aumentar o número de canais é uma das

formas mais eficazes de aumentar a acurácia. O fato de a CNN ter alcançado uma acurácia superior a 96% com apenas três canais é, portanto, um resultado significativo, indicando que a arquitetura de aprendizado profundo implementada foi capaz de extrair informações significativas e discriminativas de um conjunto de dados com baixa resolução espacial.

A análise de robustez reforçou a superioridade da CNN, enquanto o alto desvio padrão do LDA ( $\pm 6,17\%$ ) evidenciou sua sensibilidade à variabilidade do sinal, um desafio bem documentado, conforme apontado por Scheme e Englehart (2011). As matrizes de confusão aprofundam essa análise, revelando que a instabilidade do LDA se deve principalmente à sua dificuldade em separar gestos funcionalmente similares. Essa dificuldade é uma consequência direta do princípio de funcionamento do LDA, por ser um modelo que utiliza equações lineares para criar um hiperplano de separação, ele assume que as classes são linearmente separáveis no espaço de características.

No entanto, os padrões de sEMG para movimentos finos e com alta sobreposição muscular, como os de preensão, raramente satisfazem essa condição. A alta taxa de erro do LDA entre os movimentos finos sugere fortemente que seus vetores de características são linearmente inseparáveis, tornando impossível para o modelo de baixa complexidade traçar uma fronteira de decisão eficaz entre eles. A remoção de classes no cenário de 5 movimentos, portanto, atenua a principal fonte de confusão do modelo, o que explica seu ganho de acurácia desproporcionalmente maior nesse cenário mais simples.

A análise de custo-benefício computacional quantificou o *trade-off* fundamental entre os paradigmas, um ponto crucial para a viabilidade clínica de qualquer sistema de controle mioelétrico. O custo de treinamento da CNN, na ordem de 1 hora por voluntário, representa uma barreira prática significativa, especialmente em cenários que exigem recalibração frequente, um desafio já discutido por Côté-Allard *et al.* (2017). Em contraste, a rapidez de treinamento dos modelos clássicos, especialmente do LDA, oferece uma vantagem considerável em termos de implementação e manutenção.

No entanto, é fundamental distinguir o custo de treinamento, processo realizado offline, do custo de operação em tempo real. A latência de inferência de todos os modelos, incluindo a da CNN, de aproximadamente 49 ms, permaneceu confortavelmente dentro do limiar de 300 ms estabelecido pela literatura como o máximo para que o controle seja percebido como intuitivo pelo usuário (Oskoei e Hu,

2008). Isso indica que, considerando as especificações da máquina onde foi realizado todo o processamento, uma vez treinado, qualquer um dos modelos seria funcional para o controle de uma prótese.

Embora o custo de inferência de redes profundas tenha sido historicamente um obstáculo para a implementação em sistemas embarcados, o rápido avanço do poder computacional em hardware de baixo consumo está mudando este cenário. A ascensão de aceleradores de IA para dispositivos de borda (Edge AI), como Unidades de Processamento Neural (NPUs) e System-on-a-Chip (SoCs) especializados, está tornando cada vez mais viável a execução de modelos complexos, como CNNs, diretamente em dispositivos portáteis com alta eficiência energética. Portanto, embora o custo de treinamento da CNN permaneça como uma desvantagem, o custo de inferência está se tornando um desafio cada vez menor, sugerindo que a implementação embarcada de modelos de alta performance é uma direção promissora e cada vez mais realista para o futuro das próteses mioelétricas.

Por fim, é fundamental reconhecer as limitações do presente estudo para contextualização dos resultados apresentados. A principal limitação reside no número reduzido de 5 participantes, o que, embora suficiente para uma análise comparativa inicial, restringe a generalização estatística dos resultados para uma população mais ampla. Adicionalmente, os dados foram coletados em uma única sessão para cada voluntário, esta abordagem não permite a análise ampla da robustez a longo prazo, considerando inter-sessões, que é um dos maiores desafios para a viabilidade clínica de sistemas mioelétricos, como apontado por Zhang *et al.* (2013) e Côté-Allard *et al.* (2016). Variações no sinal sEMG causadas pelo reposicionamento dos eletrodos entre diferentes dias e pela fadiga ao longo de um uso prolongado não foram, portanto, avaliadas, e representam uma via crucial para investigações futuras.

## 6 CONCLUSÃO

A partir do exposto anteriormente, fica claro o desafio da classificação de movimentos finos de mão a partir de sinais de eletromiografia de superfície (sEMG), um problema complexo e com alta relevância para o desenvolvimento de próteses e interfaces mioelétricas. Diante desse cenário, este trabalho teve como objetivo central realizar uma análise comparativa dos modelos de aprendizado de máquina LDA, SVM e CNN, representando paradigmas linear, não-linear clássico e de aprendizado profundo, respectivamente.

Os objetivos específicos do trabalho foram integralmente cumpridos. A comparação de acurácia revelou uma hierarquia clara de desempenho, com a CNN alcançando a maior acurácia média de 96,46%, seguida pelo SVM com 88,58% e pelo LDA com 75,12%. A análise de robustez demonstrou que a CNN foi o modelo mais estável, apresentando o menor desvio padrão entre os participantes. Além disso, a avaliação do impacto da complexidade da tarefa mostrou que, ao reduzir o número de classes de sete para cinco, todos os modelos apresentaram ganhos de performance, mas o LDA foi o mais beneficiado, evidenciando sua sensibilidade à sobreposição de padrões musculares em tarefas mais complexas. Por fim, a análise de custo-benefício computacional quantificou o trade-off fundamental entre desempenho e eficiência: o LDA e o SVM se mostraram superiores em termos de tempo de treinamento e latência de inferência, enquanto a CNN, embora mais lenta para treinar, operou em tempo real e demonstrou a maior acurácia.

Dessa forma, foi possível concluir os objetivos propostos. A análise comparativa forneceu uma compreensão das forças e fraquezas de cada paradigma e reforçam a superioridade da CNN na classificação de movimentos finos, um campo desafiador devido à complexidade inerente do sinal mioelétrico. Para trabalhos futuros, sugere-se a validação dos resultados em um número maior de participantes e em múltiplas sessões, além de explorar técnicas como o aprendizado por transferência para mitigar o alto custo de treinamento da CNN.

## 7 REFERÊNCIAS BIBLIOGRÁFICAS

ALLARD, U. C., NOUGAROU, F., FALL, C. L., GIGUÈRE, P., GOSSELIN, C., LAVIOLETTE, F., GOSSELIN, B. A convolutional neural network for robotic arm guidance using sEMG based frequency-features. In: 2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2016. p. 2464-2470.

ATZORI, Manfredo; COGNOLATO, Matteo; MÜLLER, Henning. Deep learning with convolutional neural networks applied to electromyography data: A resource for the classification of movements for prosthetic hands. *Frontiers in neurorobotics*, v. 10, p. 9, 2016.

BASMAJIAN, John V.; DE LUCA, Carlo J. *Muscles Alive: Their Functions Revealed by Electromyography*. 5. ed. Baltimore: Williams & Wilkins, 1985.

BURDEN, A. Validity of normalisation methods for EMG data. *Journal of Electromyography and Kinesiology*, v. 20, n. 6, p. 1023–1030, 2010.

CHAN, Adrain DC; GREEN, Geoffrey C. Myoelectric control development toolbox. *CMBES Proceedings*, v. 30, 2007.

CÔTÉ-ALLARD, U., FALL, C. L., CAMPEAU-LECOURS, A., GOSSELIN, C., LAVIOLETTE, F., & GOSSELIN, B. Transfer learning for sEMG hand gestures recognition using convolutional neural networks. In: 2017 IEEE international conference on systems, man, and cybernetics (SMC). IEEE, 2017. p. 1663-1668.

DE LUCA, Carlo J. The use of surface electromyography in biomechanics. *Journal of Applied Biomechanics*, v. 13, n. 2, p. 135-163, 1997.

DE LUCA, C. J. *Surface electromyography: detection and recording*. DelSys Incorporated, 2002.

DE LUCA, C. J. The use of surface electromyography in biomechanics. *Journal of Applied Biomechanics*, v. 13, n. 2, p. 135-163, 2006.

ENGLEHART, Kevin; HUDGINS, Bernard. A robust, real-time control scheme for multifunction myoelectric control. *IEEE transactions on biomedical engineering*, v. 50, n. 7, p. 848-854, 2003.

Farina, D., Jiang, N., Rehbaum, H., Holobar, A., Graimann, B., Dietl, H., & Aszmann, O. C. The extraction of neural information from the surface EMG for the control of upper-limb prostheses: emerging avenues and challenges. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 22, n. 4, p. 797-809, 2014.

FERRIS, Daniel P.; CZERNIECKI, Joseph M.; HANNAFORD, Blake. An ankle-foot orthosis powered by artificial pneumatic muscles. *Journal of applied biomechanics*, v. 21, n. 2, p. 189-197, 2005.

GENG, W., DU, Y., JIN, W., WEI, W., HU, Y., & LI, J. Gesture recognition by

instantaneous surface EMG images. *Scientific reports*, v. 6, n. 1, p. 36571, 2016.

GU, C., PRUSZYNSKI, J. A., GRIBBLE, P. L., & CORNEIL, B. D. A rapid visuomotor response on the human upper limb is selectively influenced by implicit motor learning. *Journal of Neurophysiology*, v. 121, n. 1, p. 85-95, 2019.

GUYTON, A. C.; HALL, J. E. *Tratado de Fisiologia Médica*. 12. ed. Rio de Janeiro: Elsevier, 2011.

HAHNE, Janne M.; MARKOVIC, Marko; FARINA, Dario. User adaptation in myoelectric man-machine interfaces. *Scientific reports*, v. 7, n. 1, p. 4437, 2017.

HUDGINS, Bernard Sanford. A new approach to multifunction myoelectric control. 1992.

HUANG, X. *et al. Adaptive Normalization Strategies for Robust Myoelectric Pattern Recognition*. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 31, n. 5, p. 1024-1035, 2023.

HUDGINS, Bernard; PARKER, Philip; SCOTT, Robert N. A new strategy for multifunction myoelectric control. *IEEE transactions on biomedical engineering*, v. 40, n. 1, p. 82-94, 2002.

IQBAL, Nisheena; SUBRAMANIAM, Kamalraj; SHANIBA, Asmi. A review on upper-limb myoelectric prosthetic control. *IETE Journal of Research*, v. 64, n. 6, p. 740-752, 2018.

JIANG, N., DOSEN, S., MULLER, K. R., & FARINA, D. Myoelectric control of artificial limbs—is there a need to change focus?[In the spotlight]. *IEEE Signal Processing Magazine*, v. 29, n. 5, p. 152-150, 2012.

KAMAVUAKO, Ernest N.; SCHEME, Erik J.; ENGLEHART, Kevin B. Combined surface and intramuscular EMG for improved real-time myoelectric control performance. *Biomedical Signal Processing and Control*, v. 10, p. 102-107, 2014.

LIU, Y. *et al. Impact of Pre-Processing on EMG Pattern Recognition Robustness Under Electrode Shift*. *Journal of Neural Engineering*, v. 21, n. 2, p. 026017, 2024.

MERLETTI, R.; PARKER, P. A. *Electromyography: Physiology, Engineering, and Non-invasive Applications*. Wiley-IEEE Press, 2010.

MESIN, Luca; MERLETTI, Roberto; RAINOLDI, Alberto. Geometrical factors in surface EMG: effect of electrode location and interelectrode distance. *Journal of Electromyography and Kinesiology*, v. 14, n. 3, p. 375-386, 2004.

OLIVEIRA, A. S. C. *et al. Aplicações da eletromiografia de superfície no controle de próteses mioelétricas: uma revisão sistemática*. *Revista Brasileira de Engenharia Biomédica*, v. 36, n. 3, p. 274-287, 2020.

OSKOEI, Mohammadreza Asghari; HU, Huosheng. Myoelectric control systems a survey. *Biomedical Signal Processing and Control*, v. 2, n. 4, p. 275–294, 2007.

OSKOEI, Mohammadreza Asghari; HU, Huosheng. Support vector machine-based classification scheme for myoelectric control applied to upper limb. *IEEE transactions on biomedical engineering*, v. 55, n. 8, p. 1956-1965, 2008.

PANDEY, Babita; MISHRA, R. B. An integrated intelligent computing model for the interpretation of EMG based neuromuscular diseases. *Expert Systems with Applications*, v. 36, n. 5, p. 9201-9213, 2009.

PARKER, P.; ENGLEHART, K.; HUDGINS, B. Myoelectric signal processing for control of powered limb prostheses. *Journal of Electromyography and Kinesiology*, v. 16, n. 6, p. 541-548, 2006.

PHINYOMARK, A. *et al.* Evaluation of EMG feature extraction for hand movement recognition based on Euclidean distance and standard deviation. In: International conference on electrical engineering/electronics computer telecommunications and information technology (ECTI-CON), 2010. Anais [...]. IEEE, 2010. p. 856-860.

PHINYOMARK, A., N. KHUSHABA, R., & SCHEME, E. Feature extraction and selection for myoelectric control based on wearable EMG sensors. *Sensors*, v. 13, n. 5, p. 6280-6303, 2013.

PHINYOMARK, A.; LIMSIRORATANA, P.; PHUKPATTARAWANIT, P. A novel time-domain feature extraction method for robust EMG pattern recognition. *Journal of Computing*, v. 4, n. 7, p. 54-63, 2012.

SCHEME, E.; ENGLEHART, K. Electromyogram pattern recognition for control of powered upper-limb prostheses: State of the art and challenges for clinical use. *Journal of Rehabilitation Research & Development*, v. 48, n. 6, p. 643-660, 2011.

SCHEME, E.; ENGLEHART, K. Electromyogram pattern recognition for control of powered upper-limb prostheses: State of the art and challenges for clinical use. *Journal of Rehabilitation Research & Development*, v. 48, n. 6, p. 643-660, 2018.

TANAKA, T.; NAMBU, I.; WADA, Y. *Mitigating the Impact of Electrode Shift on Classification Performance in Electromyography-Based Motion Prediction Using Sliding-Window Normalization*. arXiv preprint arXiv:2504.03196, 2025.

ZARDOSHTI, M., WHEELER, B. C., BADIE, K., & HASHEMI, R. Evaluation of EMG features for movement control of prostheses. In: Proceedings of the 15th annual international conference of the IEEE engineering in medicine and biology society. IEEE, 1993. p. 1141-1142.