

**UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROJETO DE GRADUAÇÃO**



ARTHUR SORRENTINO FERREIRA

**ACIONAMENTO DE PRÓTESE DE MÃO POR MEIO
DE SINAIS MIOELÉTRICOS E APRENDIZADO DE
MÁQUINA**

VITÓRIA-ES
JULHO/2023

Arthur Sorrentino Ferreira

ACIONAMENTO DE PRÓTESE DE MÃO POR MEIO DE SINAIS MIOELÉTRICOS E APRENDIZADO DE MÁQUINA

Parte manuscrita do Projeto de Graduação do aluno Arthur Sorrentino Ferreira, apresentado ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Engenheiro Eletricista.

Vitória-ES
Julho/2023

Arthur Sorrentino Ferreira

ACIONAMENTO DE PRÓTESE DE MÃO POR MEIO DE SINAIS MIOELÉTRICOS E APRENDIZADO DE MÁQUINA

Parte manuscrita do Projeto de Graduação do aluno Arthur Sorrentino Ferreira, apresentado ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Engenheiro Eletricista.

Aprovado em 20 de julho de 2023.

COMISSÃO EXAMINADORA:



Prof. Dr. Teodiano Freire Bastos Filho
Universidade Federal do Espírito Santo
Orientador



Prof. Dr. Rafael Milanezi de Andrade
Universidade Federal do Espírito Santo
Coorientador



Profa. Dra. Eliete Maria de Oliveira Caldeira
Universidade Federal do Espírito Santo
Examinadora



MsC. Aura Ximena González Cely
Universidade Federal do Espírito Santo
Examinadora

Vitória-ES
Julho/2023

AGRADECIMENTOS

Gostaria de expressar meus sinceros agradecimentos a todos que estiveram envolvidos nesta importante etapa da minha vida. É com imensa gratidão que reconheço o apoio e a contribuição de cada um de vocês:

Primeiramente, agradeço a Deus, que me concedeu saúde, força e determinação para lutar pelos meus sonhos.

Aos meus pais, avó e demais familiares, que sempre me proporcionaram o suporte necessário. É graças ao esforço deles que hoje posso concluir este curso e seguir adiante.

Ao orientador e professor Teodiano Freire Bastos Filho, pelo suporte, conselhos e disponibilidade.

Ao coorientador e professor, Rafael Milanezi de Andrade, que despertou meu interesse nesse tema e me encorajou nos momentos de desânimo e insegurança.

À *startup* SymBios que forneceu o protótipo da placa de aquisição de sinais *MyoSym* e em especial ao Pedro Henrique Fabríz Ulhoa, por toda a ajuda, dicas e companheirismo durante o processo. Também agradeço à Amanda Schneider Bassani, pelas dicas de aprendizado de máquina e Python, e ao Rodrigo Corrêa da Silva, pelo esforço dedicado no ajuste de peças que decidimos modificar e pela assistência na impressão 3D.

Aos membros do Laboratório de Biomecânica e Robótica, pela companhia nas horas trabalhadas, em especial à Maria Manuela Macedo Pereira Pinheiro e ao Lucas Cocate Almeida, responsáveis pela impressão e melhorias da prótese 3D utilizada neste trabalho.

Ao meu amigo Higor David Oliveira, por me ajudar em diversas situações e pelo empréstimo de componentes para a realização deste trabalho.

Aos meus colegas de curso, companheiros nas alegrias e nas adversidades. Em especial aos amigos Yuri Rissi Negri, Igor Batista Vieira e Matheus Penido Loureiro.

Aos amigos colombianos Cristian David Guerrero Méndez e Cristian Felipe Blanco Díaz, pelas dicas sobre aprendizado de máquina e companheirismo em diversos momentos.

Aos colegas e tutores do PET Elétrica Ufes, foi uma honra ter feito parte dessa equipe durante minha graduação.

À banca examinadora pela aceitação do convite e pelo tempo investido para leitura e avaliação desse trabalho.

Ao projeto EDITAL FAPES/CNPq/Decit-SCTIE-MS/SESA N° 09/2020 PPSUS, TO: 151/2021, Projeto: 2021-8GJZ6, pelo financiamento parcial dos materiais e equipamentos necessários para o desenvolvimento deste trabalho.

Por fim, agradeço à Universidade Federal do Espírito Santo pela minha formação.

Atenciosamente,
Arthur Sorrentino Ferreira

"O sucesso é a soma de pequenos esforços repetidos dia após dia."(Robert Collier)

RESUMO

Mais de 1 bilhão de pessoas em todo o mundo convivem com algum tipo de deficiência. Além disso, a tendência é que esse número aumente, já que fatores como o envelhecimento da população, aumento do número de casos de diabetes, câncer e doenças cardiovasculares contribuem para a amputação de membros devido às complicações que podem gerar. A perda de um membro pode causar perdas significativas de mobilidade, problemas psicológicos, dificuldade de inserção no mercado de trabalho, dentre várias outras limitações para o indivíduo. Visando reduzir esses efeitos, o uso de próteses ortopédicas busca trazer de volta a autonomia, a autoestima, a integração social e a reabilitação para executar tarefas que se tornaram inviáveis. O desenvolvimento tecnológico e o surgimento de próteses biônicas têm trazido novas esperanças de recuperação de mobilidade para pessoas amputadas, porém, o alto custo desses equipamentos é um fator que restringe o acesso para a população. Sendo assim, este trabalho busca o acionamento de uma prótese de mão, feita em impressora 3D, acionada por servomotores a partir de sinais mioelétricos e aprendizado de máquina. Esta prótese foi adaptada do projeto *open-source* InMoov, havendo sido adicionada à placa de aquisição de sinais mioelétricos *MyoSym*, protótipo desenvolvido pela *startup* capixada SymBios, para a captura da atividade muscular. Os algoritmos de aprendizado de máquina SVM (*Support Vector Machine*) e KNN (*K-Nearest Neighbors*) foram utilizados para a classificação dos movimentos de pinça, flexão e extensão da mão, visando o acionamento da prótese. Esses algoritmos apresentaram acurácia de 86,25% e 85,00%, respectivamente, no acionamento em tempo real, demonstrando que a abordagem adotada é promissora como uma proposta de custo reduzido para controle de próteses mioelétricas.

Palavras - chave: Aprendizado de Máquina, Eletromiografia, Impressão 3D, Prótese de mão, Reabilitação.

ABSTRACT

More than 1 billion people around the world live with some form of disability. In addition, the trend is for this number to increase, as factors such as aging population, increase in the number of cases of diabetes, cancer and cardiovascular diseases contribute to the amputation of limbs due to the complications they can generate. The loss of a limb can cause significant loss of mobility, psychological problems, difficulty in entering the job market, among many other limitations for the individual. In order to reduce these effects, the use of orthopedic prostheses seeks to bring back autonomy, self-esteem, social integration, and rehabilitation to perform tasks that have become unfeasible. Technological development and emergence of bionic prostheses have brought new hope of mobility recovery to amputees, however, the high cost of this equipment is a factor that restricts access for the population. Therefore, this work seeks to drive a hand prosthesis, made in a 3D printer, driven by servomotors from myoelectric signals and machine learning. This prosthesis was adapted from the open-source InMoov project, with the addition of the myoelectric signal acquisition board *MyoSym*, a prototype developed by the Brazilian startup SymBios, to capture muscle activity. The machine learning algorithms SVM (Support Vector Machine) and KNN (K-Nearest Neighbors) were used to classify the pinching, flexion and extension movements of the hand, aiming at activating the prosthesis. These algorithms showed an accuracy of 86.25% and 85.00%, respectively, in real-time activation, demonstrating that the adopted approach is promising as a low-cost proposal for controlling myoelectric prostheses.

Keywords: 3D Printer; Electromyography; Hand prosthesis; Machine Learning; Rehabilitation.

LISTA DE FIGURAS

Figura 1 – Movimentos dos Dedos	14
Figura 2 – Inserções Musculares nos ossos da mão, vista palmar	15
Figura 3 – Movimentos do Punho	16
Figura 4 – Músculos Extensores do Punho	16
Figura 5 – Músculos Flexores do Punho	17
Figura 6 – Músculos que auxiliam a Extensão do Punho	17
Figura 7 – Níveis de Amputação do Membro Superior	19
Figura 8 – Prótese de mão - <i>Ottobock Bebionic Flex Hand</i>	20
Figura 9 – Prótese de mão - <i>i-Limb Quantum</i>	20
Figura 10 – Despolarização e Repolarização da Membrana Celular	22
Figura 11 – Sinal sEMG bruto (<i>raw signal</i>) gravado da contração do músculo bíceps braquial	23
Figura 12 – Esquema de reconhecimento de padrões de sEMG para controle de próteses	24
Figura 13 – Evolução do sEMG como Controle para Prótese de Mão	31
Figura 14 – Fase 1 - Treinamento do modelo de <i>Machine Learning</i>	33
Figura 15 – Fase 2 - Acionamento da prótese	33
Figura 16 – <i>MyoSym</i> (Symbios)	34
Figura 17 – Posição dos 3 canais no antebraço do usuário	35
Figura 18 – Prótese de mão feita em impressora 3D	38
Figura 19 – Esquemático de ligação do sistema para controle da prótese	39
Figura 20 – Sinal Bruto - Flexão	42
Figura 21 – Sinal Filtrado - Flexão	42
Figura 22 – Sinal Bruto - Extensão	43
Figura 23 – Sinal Filtrado - Extensão	43
Figura 24 – Sinal Bruto - Pinça	44
Figura 25 – Sinal Filtrado - Pinça	44
Figura 26 – Características extraídas durante a captura da Flexão	46
Figura 27 – Características extraídas durante a captura da Extensão	47
Figura 28 – Características extraídas durante a captura da Pinça	48
Figura 29 – Matriz de Confusão - KNN	50
Figura 30 – Matriz de Confusão - SVM	52
Figura 31 – Matriz de Confusão - Tempo Real - KNN	54
Figura 32 – Matriz de Confusão - Tempo Real - SVM	54

LISTA DE TABELAS

Tabela 1 – Músculos da mão, localização e função	15
Tabela 2 – Músculos do antebraço, localização e função	18
Tabela 3 – Matriz de confusão de um classificador	28
Tabela 4 – Protocolo de Captura dos Dados	35
Tabela 5 – Protocolo de Teste da Classificação em Tempo Real	39
Tabela 6 – Métricas de Desempenho - Classificação	52
Tabela 7 – Métricas de Desempenho - Processamento em Tempo Real	55

LISTA DE ABREVIATURAS E SIGLAS

CNN	<i>Convolutional Neural Network</i>
CSV	<i>Comma Separated Values</i>
EMG	Eletromiografia
FN	Falso Negativo
FP	Falso Positivo
IA	Inteligência Artificial
IMU	<i>Inertial Measurement Unit</i>
I2C	<i>Inter-Integrated Circuit</i>
KNN	<i>K-Nearest Neighbors</i>
LDA	<i>Linear Discriminant Analysis</i>
MAV	<i>Mean Absolute Value</i>
MAVSLP	<i>Mean Absolute Value Slope</i>
ML	<i>Machine Learning</i>
MUAP	<i>Motor Unity Action Potential</i>
OMS	Organização Mundial da Saúde
PLA	Ácido Poliláctico
RF	<i>Random Forest</i>
RMS	<i>Root Mean Square</i>
SD	<i>Secure Digital Card</i>
sEMG	Sinal Eletromiográfico de Superfície
SIHSUS	Sistema de Informações Hospitalares do SUS
SSC	<i>Slope Sign Change</i>
SSI	<i>Simple Square Integral</i>
SUS	Sistema Único de Saúde

SVM	<i>Support Vector Machine</i>
UFES	Universidade Federal do Espírito Santo
USB	<i>Universal Serial Bus</i>
VAR	Variância
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo
WL	<i>Waveform Length</i>
ZC	<i>Zero Crossing</i>

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Motivação	12
1.2	Objetivos	13
1.2.1	Objetivo Geral	13
1.2.2	Objetivos Específicos	13
1.3	Organização do Trabalho	13
2	REFERENCIAL TEÓRICO	14
2.1	Músculos Responsáveis pelos Movimentos da Mão e do Punho	14
2.2	Tipos de Amputações	19
2.3	Próteses	20
2.4	Eletromiografia	21
2.5	Eletrodos	23
2.6	Reconhecimento de Padrões para Controle da Prótese	24
2.7	Aprendizado de Máquina	26
2.8	Trabalhos Relacionados	30
3	METODOLOGIA E ETAPAS DE DESENVOLVIMENTO	33
3.1	Metodologia Adotada	33
4	RESULTADOS E DISCUSSÃO	40
4.1	Pré-processamento dos Dados	41
4.2	Extração de Características	45
4.3	Treinamento do Modelo e Classificação	49
4.4	Processamento em Tempo Real	53
5	CONCLUSÃO E TRABALHOS FUTUROS	56
	REFERÊNCIAS	58

1 INTRODUÇÃO

1.1 Motivação

Amputação, ou retirada total ou parcial de um membro, ocorre para salvar a vida do paciente ou melhorar a sua saúde física. Entretanto, isto gera consequências como a perda de autonomia, já que o indivíduo reduz a capacidade de realizar simples atividades no dia-a-dia. A amputação também pode gerar transtornos como perda da autoestima, depressão, sentimento de inferioridade e dificuldade de inserção no mercado de trabalho.

Entretanto, deve-se ressaltar que a amputação não pode ser considerada como o fim, mas sim como o início de uma nova fase, que necessita de adaptações (BOTH et al., 2011). E nesse contexto, a reabilitação por meio do uso de próteses se torna essencial.

As próteses de membro superior podem ser divididas em passivas ou ativas. As próteses passivas são mais simples e possuem menor custo, porém, são dispositivos estáticos ou que realizam movimento específico com base num mecanismo acionado por alguma parte do corpo. Nesse tipo de prótese há maior dificuldade de adaptação do indivíduo, além de menor funcionalidade. Já as próteses ativas conseguem executar determinadas funções que o membro amputado desempenhava, o que facilita a adaptação do usuário (CRUZ et al., 2018). Porém, apresentam alta complexidade e custo, o que restringe o acesso para a população (BUFFONE, 2013) (CAMARGO; STOPPA, 2015).

Este trabalho busca o acionamento de uma prótese de mão de custo reduzido, feita em impressora 3D, e acionada por sensores mioelétricos. A prótese foi feita com base no projeto *open-source* da empresa InMoov (INMOOV, 2014). Ela é composta por servomotores que, ao serem acionados, tracionam tendões responsáveis por flexionar/estender os dedos. Para a captura do sinal muscular é utilizada a placa de aquisição de sinais mioelétricos *MyoSym* (SYMBIOS, 2023). Ela possui 3 canais diferenciais que são posicionados no antebraço do usuário, visando diferenciar os movimentos de pinça, flexão e extensão da mão. Para processamento dos dados capturados, é feita a filtragem, extração de características dos sinais e rotulagem das classes. Em seguida, o resultado é enviado para um algoritmo de Aprendizagem de Máquina (em inglês, *Machine Learning* - ML) como o KNN (*K-Nearest Neighbors*) ou o SVM (*Support Vector Machine*), visando o treinamento de um modelo para classificação dos movimentos. Com o modelo treinado, é realizado um processamento *online*, buscando o acionamento da prótese em tempo real de acordo com o que é desejado pelo usuário.

1.2 Objetivos

1.2.1 Objetivo Geral

O objetivo geral deste Trabalho de Conclusão de Curso é o acionamento de uma prótese de mão, feita em impressora 3D e controlada por sinais mioelétricos, por meio de diferentes algoritmos de Aprendizagem de Máquina.

1.2.2 Objetivos Específicos

- Utilizar plataforma de aquisição de sinais mioelétricos que seja de baixo custo para controle da prótese de mão.
- Implementar algoritmos de Aprendizagem de Máquina para classificação dos padrões de movimentos definidos (abrir/fechar a mão e movimento de pinça).
- Fazer o comparativo entre diferentes algoritmos de Aprendizagem de Máquina e encontrar qual o mais adequado para o problema proposto.

1.3 Organização do Trabalho

Este trabalho está dividido em 4 capítulos:

1. Introdução: neste capítulo é realizada uma abordagem sobre o tema em estudo.
2. Referencial Teórico: neste capítulo são abordados conceitos fundamentais para o entendimento do trabalho, como eletromiografia, músculos do antebraço e punho, tipos de amputações, próteses e algoritmos de *Machine Learning*.
3. Metodologia e Etapas de Desenvolvimento: este capítulo mostra quais ferramentas e escolhas foram realizadas para atingir o objetivo esperado.
4. Resultados e Discussão: este capítulo relata os resultados encontrados no desenvolvimento do trabalho.
5. Conclusão e Trabalhos Futuros: este capítulo apresenta um resumo do que foi obtido com o desenvolvimento deste projeto, assim como cita possíveis melhorias a serem feitas.

2 REFERENCIAL TEÓRICO

2.1 Músculos Responsáveis pelos Movimentos da Mão e do Punho

Um número relativamente grande de músculos é responsável pelos movimentos realizados pela mão e dedos (HALL, 2000). Esses músculos podem ser classificados em extrínsecos e em intrínsecos (FABRIS, 2022). Os músculos extrínsecos são aqueles que se originam fora da mão e se ligam a ela, responsáveis por movimentos de força. São divididos em flexores e extensores. Já os músculos intrínsecos são aqueles com origem dentro da mão, responsáveis por movimentos mais precisos dos dedos (FABRIS, 2022).

Os músculos da mão conseguem mover os dedos em 4 direções: flexão, extensão, abdução e adução, conforme pode ser observado na Figura 1 (SOBOTTA, 2000).

Figura 1 – Movimentos dos Dedos



Fonte: Sobotta (2000)

Cruz et al. (2018) listaram os músculos da mão e os relacionaram com as funções que podem executar. Isso pode ser observado na Tabela 1. Já a Figura 2 mostra como são localizados os músculos da mão.

Em relação ao punho, tem-se que é capaz de realizar movimentos nos planos sagital e frontal, assim como movimento rotacional (HALL, 2000). Dentre os possíveis movimentos, podem-se destacar a extensão, a flexão, o desvio radial e o desvio ulnar, conforme ilustrado pela Figura 3.

Além disso, tem-se que os músculos do antebraço são fundamentais nos movimentos exercidos pela mão e punho (CRUZ et al., 2018). Segundo Cruz et al. (2018), este membro é composto por 20 músculos divididos em 3 grupos de acordo com a respectiva localização: anterior, posterior e lateral. Sendo assim, a Tabela 2 apresenta os músculos do antebraço e quais movimentos eles são responsáveis


Em seguida, as Figuras 4 e 5 mostram os principais músculos do antebraço acionados quando realizam os movimentos de extensão e flexão, respectivamente. Por fim, a Figura 6 mostra os músculos auxiliares na extensão.

Tabela 1 – Músculos da mão, localização e função

Músculos da mão		
Região	Músculo	Função
Palmar lateral (4 músculos)	Abdutor curto do polegar	Abdução e flexão do polegar
	Flexor curto do polegar	Flexão do polegar
	Oponente do polegar	Oposição do polegar (flexão + adução + pronação)
	Abdutor do polegar	Adução do polegar
Palmar medial (4 músculos)	Palmar curto	Pregas transversais na região hipotenar
	Abdutor do mínimo	Abdução do dedo mínimo
	Flexor curto do mínimo	Flexão do dedo mínimo
	Oponente do mínimo	Oposição do dedo mínimo
Palmar média (11 músculos)	Lumbricais	Flexão e extensão da interfalangeana proximal e distal do 2º ao 5º dedos Propriocepção dos dedos
	Interósseos palmares	Adução dos dedos
	Interósseos dorsais	Abdução dos dedos


Fonte: Adaptado de Cruz et al. (2018)

Figura 2 – Inserções Musculares nos ossos da mão, vista palmar




Fonte: Adaptado de Sobotta (2000) por Cruz et al. (2018)

Figura 3 – Movimentos do Punho




Fonte: Hall (2000)

Figura 4 – Músculos Extensores do Punho




Fonte: Hall (2000)

Figura 5 – Músculos Flexores do Punho



Fonte: Hall (2000)

Figura 6 – Músculos que auxiliam a Extensão do Punho



Fonte: Hall (2000)

Tabela 2 – Músculos do antebraço, localização e função

Músculos do antebraço			
Grupo	Camada	Músculo	Função
Anterior	Superficial	Pronador redondo	Flexão e pronação
		Flexor radial do carpo	Flexão, pronação e abdução da mão
		Palmar longo	Flexão palmar
	Profunda	Flexor superficial dos dedos	Flexão, abdução e adução dos dedos
		Flexor ulnar do carpo	Abdução da mão
		Flexor profundo dos dedos	Flexão palmar e adução da mão
		Flexor longo do polegar	Flexão palmar e adução da mão
	Pronador quadrado	Pronação	
Lateral		Braquiorradial	Flexão, pronação e supinação da mão
		Extensor radial longo do carpo	Flexão, pronação e supinação da mão
		Extensor radial curto do carpo	Flexão e abdução da mão
Posterior	Superficial	Extensor dos dedos	Extensão e dorso flexão dos dedos
		Extensor do dedo mínimo	Extensão e dorso flexão do mínimo
		Extensor ulnar do carpo	Extensão, dorso flexão e abdução da mão
		Supinador	Supinação
	Profunda	Extensor longo do polegar	Abdução, adução e extensão do polegar
		Extensor do indicador	Extensão do indicador
		Abdutor longo do polegar	Abdução do polegar e da mão
		Extensor curto do polegar	Extensão do polegar e abdução da mão

Fonte: Adaptado de Cruz et al. (2018)

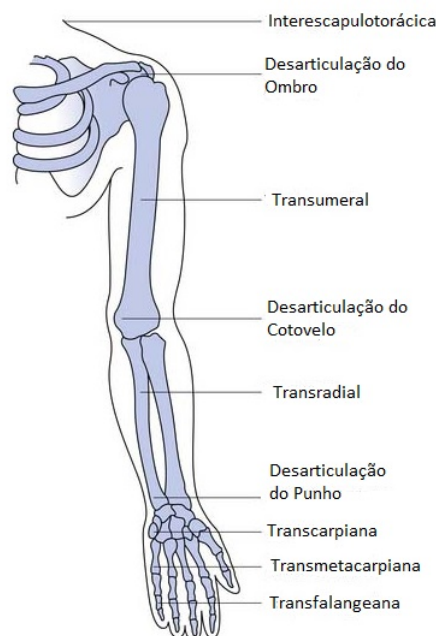
2.2 Tipos de Amputações

Segundo o Ministério da Saúde - Brasil (2013), "amputação é o termo utilizado para definir a retirada total ou parcial de um membro".

Peixoto et al. (2017) realizaram um estudo sobre a prevalência de amputações de membros superiores e inferiores no estado de Alagoas atendidos pelo Sistema Único de Saúde (SUS) entre 2008 e 2015. Utilizando dados do Sistema de Informações Hospitalares do Sistema Único de Saúde (SIHSUS) - Brasil (2016), viram que 361.585 procedimentos de amputações foram realizados em todo o Brasil nesse período. Desse total, pôde-se observar que a maior parcela foi referente a amputações de membros inferiores, correspondendo a uma média de 12,35 amputações por 100 mil habitantes/ano, sendo que a causa principal foram as doenças vasculares periféricas e o diabetes mellitus. Já em relação às amputações de membro superior, a principal causa são os traumas (por exemplo: acidentes de trânsito, acidentes de trabalho, projéteis de armas de fogo) (JORGE et al., 2020).

A Figura 7 mostra os níveis de amputação do membro superior, são eles: Interscapulotorácica; Desarticulação do ombro; Transumeral; Desarticulação do cotovelo; Transradial; Desarticulação do Punho; Transcarpiana; Transmetacarpiana e Transfalangeana (SHEEHAN, 2015).

Figura 7 – Níveis de Amputação do Membro Superior



Fonte: Adaptado de Sheehan (2015)

A escolha do nível da amputação sempre deve buscar preservar a maior parte do membro possível, já que dessa forma, mais músculos estarão preservados, tornando mais confiável a aquisição de sinais mioelétricos e também facilitando a adequação a uma prótese (CRUZ et al., 2018; BRASIL, 2013).

2.3 Próteses

As próteses podem ser classificadas em passivas ou ativas (CRUZ et al., 2018). Próteses passivas normalmente são dispositivos que não realizam movimento para o usuário, são mais simples e possuem um custo mais baixo. Já as próteses ativas conseguem realizar vários movimentos e executar determinadas funções que o membro amputado desempenhava. São mais complexas e mais caras, podendo ser elétricas, pneumáticas ou ainda serem acionadas pela contração muscular. Nesse caso são chamadas de próteses mioelétricas e comprovam a eficiência do uso da eletromiografia para reabilitação, já que permitem que o usuário execute tarefas que não são possíveis com próteses convencionais (CRUZ et al., 2018; LOPES, 2022; JORGE et al., 2020).

Dentre as principais próteses mioelétricas de mão disponíveis no mercado, pode-se citar a *Ottobock Bebionic Flex Hand* (OTTOBOCK, 2020) e a *i-Limb Quantum* (OSSUR, 2021), conforme Figuras 8 e 9. São próteses que realizam diversos tipos de movimentos e contam com funcionalidades que proporcionam maior precisão e conforto para o usuário. (WILLIAMS, 2022; BUFFONE, 2013).

Figura 8 – Prótese de mão - *Ottobock Bebionic Flex Hand*



Fonte: Ottobock (2020)

Figura 9 – Prótese de mão - *i-Limb Quantum*



Fonte: Ossur (2021)

2.4 Eletromiografia


A primeira dedução de que os músculos poderiam gerar eletricidade foi feita em 1666 por Francesco Redi (1626-1691) (BIEDERMANN; WELBY, 1898; ANDRADE, 2007). Ao observar arraias elétricas, ele suspeitou que a eletricidade produzida por esse peixe fosse proveniente de seus músculos (BIEDERMANN; WELBY, 1898). Já no século seguinte, em 1791, Luigi Galvani (1737-1798), por meio de experimentos com sapos e rãs, observou a relação entre a contração muscular e a eletricidade (GALVANI; ALDINI et al., 1792; ANDRADE, 2007). Posteriormente, em 1849, Du Bois-Reymond (1818-1896) foi o primeiro a relatar a detecção de sinais elétricos dos músculos humano (BOIS-REYMOND, 1849). Para isso ele desenvolveu uma espécie de eletrodo composto por um fio ligado a um papel imerso em uma solução salina. Ao monitorar o sistema com um galvanômetro, ele imergiu os dedos na solução e, ao contrair os músculos do braço e da mão, percebeu que o ponteiro se mexia (BOIS-REYMOND, 1849; BASMAJIAN, 1962). Nos anos seguintes, vários cientistas contribuíram com descobertas e avanços relacionados à eletromiografia (EMG), de forma que hoje ela é uma ferramenta utilizada em diversos campos como: pesquisa médica (ortopedia, análise de marcha e postura, neurologia funcional), reabilitação (pós cirurgia, fisioterapia, reabilitação neurológica), ergonomia (prevenção de riscos, projeto ergonômico, certificação de produtos) e esportes (biomecânica, análise de movimento, reabilitação esportiva, cinesiologia) (KONRAD, 2006).

A eletromiografia é uma técnica que registra os sinais elétricos gerados pelas variações fisiológicas das membranas das fibras musculares, o que possibilita analisar a atividade muscular do movimento realizado. Quando esses sinais são coletados na superfície da pele, a técnica é chamada de eletromiografia de superfície (em inglês, *surface Electromyography* - sEMG) (AQUINO, 2005; KONRAD, 2006).

Basicamente tem-se que os sinais mioelétricos ocorrem quando o cérebro aciona uma unidade motora, que irá acionar e contrair as respectivas fibras musculares (JUNIOR, 2021). Uma unidade motora é o conjunto entre um neurônio motor e as fibras musculares, sendo que o neurônio motor é o responsável por comandar a contração das respectivas fibras (GODOI, 2014).

Para entender como a contração muscular gera eletricidade, é necessário analisar o modelo das membranas semipermeáveis, que pode ser observado na Figura 10 (KONRAD, 2006). Tem-se que durante o repouso a membrana celular é permeável aos íons K^+ (Potássio), mas impermeável aos íons Na^+ (Sódio). Nesse momento a diferença iônica entre os meios intra e extra-celular corresponde a um potencial de cerca de -80 mV, que é mantido por um processo fisiológico conhecido como "Bomba de Sódio-Potássio", o qual é um mecanismo que realiza o transporte ativo dos íons Na^+ para fora da célula e os íons K^+ para dentro da célula. Quando ocorre a contração muscular, ou seja, a ativação de uma unidade motora, as características de difusão da membrana da fibra muscular

Figura 10 – Despolarização e Repolarização da Membrana Celular




Fonte: Adaptado de Konrad (2006)

são brevemente modificadas e os íons Na^+ fluem para dentro da célula. Esse processo é conhecido como despolarização da membrana e com isso a diferença de potencial entre os meios intra e extra-celular passa a ser de cerca de +30 mV. Porém, rapidamente a membrana volta a ser impermeável aos íons Na^+ , gerando a repolarização, etapa na qual a concentração de íons Na^+ no interior da célula diminui, e a diferença de potencial entre os meios intra e extra-celular volta a ser de cerca de -80 mV (KONRAD, 2006; SILVA, 2010; JUNIOR, 2021).

Sendo assim, quando ocorre a ativação de uma unidade motora, as respectivas fibras musculares são despolarizadas/repolarizadas. O resultado da soma algébrica de vários potenciais das n fibras acionadas é chamado de Potencial de Ação da Unidade Motora/ "Motor Unit Action Potential" (MUAP) (KONRAD, 2006; VIANA, 2019; MAYOR, 2017). A combinação de MUAPs forma o sEMG (LOPES, 2022). A Figura 11 mostra como é um sinal sEMG bruto, isto é, um sinal original que não foi filtrado ou processado.

No que diz respeito às características dos sinais mioelétricos, tem-se que sua amplitude média varia de cerca de 50 μV a 5 mV, dependendo do músculo analisado, localização dos eletrodos e nível de contração muscular. Além disso, a faixa de frequência do sinal sEMG será de cerca de 500 Hz, portanto, segundo o Teorema de Nyquist, a taxa de amostragem deve ser pelo menos o dobro desse valor para que não haja perda de informação (BRONZINO; PETERSON, 2014; LATHI; GREEN, 2005).

Figura 11 – Sinal sEMG bruto (*raw signal*) gravado da contração do músculo bíceps braquial

Fonte: Adaptado de Konrad (2006)

2.5 Eletrodos

No que diz respeito à forma de captura do sinal, os eletrodos costumam ser classificados em duas categorias: eletrodos de superfície ou eletrodos de profundidade (também chamados de eletrodos invasivos) (JUNIOR, 2021; GODOI, 2014).

- **Eletrodos de Superfície:** são eletrodos não invasivos e fáceis de manipular. Se assemelham a discos metálicos comumente feitos de prata (Ag) ou cloreto de prata (AgCl). Normalmente são colocados sobre a pele em conjunto com um gel/pasta condutora que tem a finalidade de facilitar a condução dos potenciais elétricos, diminuindo a impedância entre o eletrodo e a pele. Recomenda-se a preparação da pele por meio da lavagem, limpeza com álcool e raspagem dos pelos (MAYOR, 2017; JUNIOR, 2021; GODOI, 2014). A principal desvantagem desse tipo de eletrodo é o fenômeno chamado *crosstalk*, que é uma interferência que pode alterar o sinal coletado. Ela pode ser proveniente de outros músculos adjacentes, tecidos ou qualquer material que emita um campo elétrico que afete os eletrodos (SILVA, 2010). No que diz respeito à pré-amplificação, os eletrodos podem ser divididos em ativos ou passivos. (TOMÉ, 2015) São eletrodos ativos quando captam o sinal e realizam a pré-amplificação no próprio eletrodo. São passivos quando não possuem esse estágio de pré-amplificação, assim, apenas captam o sinal e enviam para outro dispositivo amplificar, o que torna este tipo de eletrodo suscetível a ruídos provenientes do movimento dos cabos e *crosstalk* (TOMÉ, 2015).
- **Eletrodos de Profundidade:** são eletrodos invasivos, constituídos de fios que são inseridos por uma agulha no interior do músculo. Isto torna o método mais preciso devido à redução do *crosstalk*, entretanto, o desconforto causado e a necessidade de

um profissional treinado para fazer o procedimento sem causar danos ao paciente, fazem esse método ser menos utilizado (JUNIOR, 2021; GODOI, 2014).

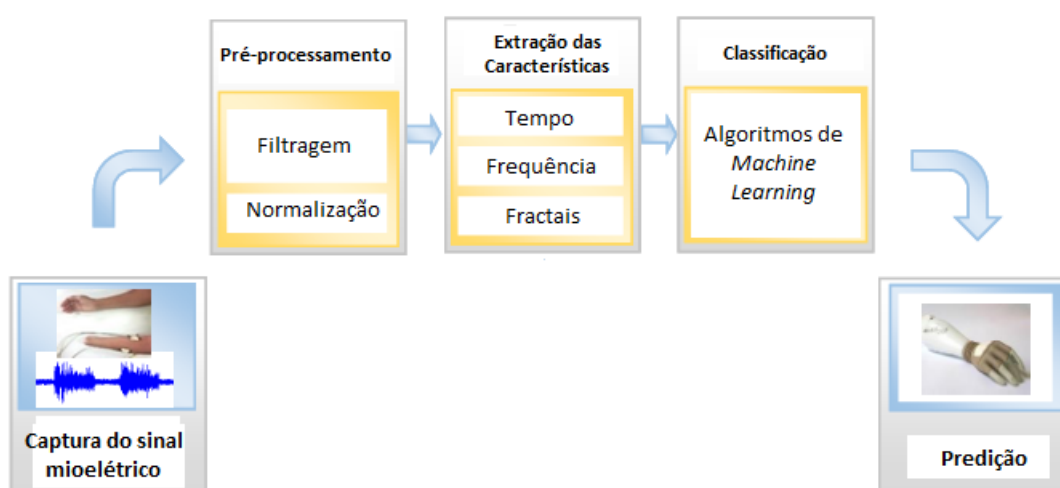
Os eletrodos também podem ser classificados pelo número de contatos elétricos (JUNIOR, 2021). Sendo assim, tem-se as seguintes classificações:

- **Monopolar:** eletrodo que possui 1 contato elétrico. Nessa configuração, um eletrodo é colocado no músculo de interesse e outro é utilizado como referência, sendo colocado num ponto não afetado pelo músculo analisado, e assim mede-se a diferença de potencial entre os dois eletrodos (JUNIOR, 2021).
- **Bipolar:** eletrodo que possui 2 contatos elétricos. Nessa configuração, os dois contatos elétricos são posicionados na região de interesse e um outro eletrodo é utilizado como referência, sendo colocado num ponto não afetado pelo músculo analisado. Assim, mede-se a diferença de potencial entre os dois contatos elétricos (JUNIOR, 2021). Fazendo o uso de um amplificador diferencial nesta configuração, tem-se a eliminação do ruído comum aos dois sinais, o que faz essa configuração ser bastante utilizada (TOMÉ, 2015).

2.6 Reconhecimento de Padrões para Controle da Prótese

No que diz respeito ao acionamento das próteses por meio de eletromiografia e reconhecimento de padrões, podem-se resumir as etapas conforme o esquema ilustrado na Figura 12.

Figura 12 – Esquema de reconhecimento de padrões de sEMG para controle de próteses



Fonte: Adaptado de Mayor (2017)

A primeira etapa é a captura do sinal. É importante que os movimentos realizados sejam feitos na mesma condição (mesma posição dos sensores e movimentos padronizados),

assim como deve ser feita a remoção dos pelos e limpeza com álcool 70% na região da pele onde serão aplicados os eletrodos.

Com os dados capturados, é realizado o pré-processamento. Esta etapa tem o objetivo de tratar os dados e eliminar possíveis interferências. Para isso são aplicados filtros digitais, como o filtro *Butterworth*. Este filtro é o mais recomendado para sinais sEMG (LOPES, 2022). É definido apenas por dois parâmetros (número de pólos e frequência de corte). Além disso, conforme Velloso (2004) "em um filtro ideal a resposta em fase deve ser linear para todas as frequências, e a atenuação do sinal deve ser precisa e rápida". E o filtro *Butterworth* é o que apresenta a melhor relação entre a resposta em fase e velocidade de atenuação.

Com os dados tratados, é realizada a extração das características, através de métodos matemáticos utilizados para obter informações dos dados capturados. Com os valores extraídos é possível distinguir os padrões de movimento. As características podem ser no domínio do tempo, domínio da frequência ou no domínio tempo-frequência.

As características no domínio do tempo geralmente exigem um processamento computacional mais simples que as no domínio da frequência e, por esse motivo, serão as escolhidas para o desenvolvimento deste trabalho (LOPES, 2022).

Exemplificando algumas características no domínio do tempo: *Root Mean Square* (RMS), *Waveform Length* (WL), *Zero Crossing* (ZC), *Simple Square Integral* (SSI), *Mean Absolute Value* (MAV) e *Variance* (VAR) representadas pelas Equações 2.1, 2.2, 2.3, 2.4, 2.5 e 2.6, onde N corresponde ao número total de amostras e X_i corresponde à amostra na posição i dentre as N amostras totais.

O RMS é a raiz quadrada média e representa a força constante do músculo (LOPES, 2022; SPIEWAK et al., 2018). É útil para avaliar a ativação muscular ao longo do tempo (ZHANG et al., 2019). Para calcular esta *feature*, o sinal é elevado ao quadrado em cada amostra e, em seguida, é encontrada a média desses valores. Por fim, é calculada a raiz quadrada da média, conforme Equação 2.1.

Já o WL é o comprimento cumulativo da forma de onda no intervalo selecionado (LOPES, 2022; SPIEWAK et al., 2018). Está relacionado à forma de onda da amplitude, frequência e tempo e pode ser usado para medir a complexidade do sinal (ZHANG et al., 2019). Para calcular o WL, toma-se a soma das diferenças absolutas entre amostras consecutivas do sinal, conforme Equação 2.2.

O ZC conta o número de vezes que um sinal atravessa o eixo zero e é frequentemente utilizado para quantificar a taxa de mudança de um sinal (MAYOR, 2017). Sua fórmula, conforme Equação 2.3, pode ser interpretada como a soma da diferença absoluta entre os valores da função sinal ($sgn(X[i])$) em amostras consecutivas. Sendo que ($sgn(X[i])$) é a função sinal que retorna 1 se $X[i] > 0$, -1 se $X[i] < 0$, e 0 se $X[i] = 0$.

O SSI é a integral quadrada simples e expressa a energia do sinal sEMG (LOPES, 2022; SPIEWAK et al., 2018). Para calcular, eleva-se o valor absoluto do sinal ao quadrado

em cada amostra e, em seguida, soma-se esses valores, conforme Equação 2.4.

O MAV é o valor absoluto médio e detecta o nível de contração muscular (LOPES, 2022; SPIEWAK et al., 2018). Para calcular, toma-se a média dos valores absolutos das amostras do sinal, conforme Equação 2.5.

O VAR é a variância do sinal e é uma medida que representa a variabilidade do sinal sEMG. Em outras palavras, representa a dispersão dos dados em relação a média (SOUZA, 2021). Para calcular, primeiro, calcula-se a média do sinal e, em seguida, para cada amostra do sinal, calcula-se a diferença entre o valor da amostra e a média, eleva-se essa diferença ao quadrado e, finalmente, divide o valor encontrado por (N-1), conforme Equação 2.6.

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N X_i^2} \quad (2.1)$$

$$WL = \sum_{i=1}^N |X_{i+1} - X_i| \quad (2.2)$$

$$ZC = \frac{1}{2} \cdot \sum |sgn(X[i]) - sgn(X[i - 1])| \quad (2.3)$$

$$SSI = \sum_{i=1}^N |X_i|^2 \quad (2.4)$$

$$MAV = \frac{1}{N} \sum_{i=1}^N |X_i| \quad (2.5)$$

$$VAR = \frac{1}{N-1} \sum_{i=1}^N |X_i - \bar{X}| \quad (2.6)$$

Com as características selecionadas, um método para classificação dos dados deve ser escolhido, como por exemplo: *Linear Discriminant Analysis* (LDA), *Support Vector Machine* (SVM), *K-Nearest Neighbors* (KNN), dentre outros. Os classificadores irão associar o padrão reconhecido de acordo com o movimento executado e, de acordo com isso, a prótese será acionada.

2.7 Aprendizado de Máquina

Segundo Monard e Baranauskas (2003) o Aprendizado de Máquina, também conhecido como *Machine Learning*, "é uma área de Inteligência Artificial (IA) cujo objetivo é o desenvolvimento de técnicas computacionais sobre o aprendizado bem como a construção de sistemas capazes de adquirir conhecimentos de forma automática". Em outras palavras, o ML busca desenvolver modelos capazes de aprender e realizar tarefas.

Atualmente, os algoritmos de Aprendizado de Máquina costumam ser divididos em 4 tipos: Aprendizado Supervisionado, Não Supervisionado, Semisupervisionado e Por Reforço (VELEDA, 2019).

No aprendizado supervisionado, o algoritmo recebe os dados de treino devidamente rotulados com as respectivas classes e assim, quando receber novas amostras, irá identificar a qual classe aquele dado pertence. Já no aprendizado não supervisionado, o algoritmo recebe os dados sem nenhum rótulo e busca encontrar padrões e formar agrupamentos com esses dados iniciais. Já no aprendizado semisupervisionado é utilizada uma combinação de dados rotulados e não rotulados para treinar os modelos. E por fim, no aprendizado por reforço, os algoritmos aprendem por tentativa e erro (VELEDA, 2019).

Buscando resolver o problema de classificação multiclasse proposto neste trabalho, foram selecionados 4 algoritmos que serão utilizados como supervisionados: KNN (*K-Nearest Neighbors*), SVM (*Support Vectors Machine*), LDA (*Linear Discriminant Analysis*) e RF (*Random Forest*).

O KNN, que pode ser traduzido como "K-vizinhos mais próximos", é um algoritmo de classificação e regressão. Ele atribui uma classificação a um novo dado com base nas características dos dados existentes mais semelhantes a ele. Segundo Ferrero (2009) "a ideia geral desse algoritmo consiste em encontrar os k exemplos rotulados mais próximos do exemplo não classificado e, com base no rótulo desses exemplos mais próximos, é tomada a decisão relativa à classe do exemplo não rotulado."

O SVM consiste em um algoritmo de aprendizado de máquina bastante utilizado para classificação e regressão. Ele busca encontrar um hiperplano que maximize a margem de separação entre as diferentes classes de dados. Esse hiperplano é definido como uma fronteira que separa os exemplos de treinamento em diferentes classes (SEMOLINI et al., 2002).

Já o LDA é um método usado em *Machine Learning* e estatística para reconhecimento de padrões, exploração e classificação de grandes conjuntos de dados. É uma generalização do Discriminante Linear de Fischer (FISHER, 1936), e busca encontrar uma combinação linear que irá diferenciar duas ou mais classes. Essa combinação pode ser utilizada como classificador linear ou para reduzir a dimensionalidade do conjunto de dados (REZENDE; FILHO; VIEIRA, 2019; SILVA et al., 2017; BOELTER, 2021).

Por fim, o RF é um algoritmo que combina diversas árvores de decisão individuais para realizar tarefas de classificação e regressão. Conforme definido por Breiman (2001) e traduzido por Oshiro (2013), o RF consiste numa "coleção de árvores $\{h_k(x, \theta_k), k = 1, 2, \dots\}$, onde θ_k são amostras aleatórias independentes e identicamente distribuídas e cada árvore vota na classe mais popular para a entrada x ".

Durante o treinamento do modelo, os dados são divididos em conjuntos de treino e teste. Essa separação é realizada para permitir que o modelo aprenda padrões dos dados no conjunto de treino e, posteriormente, seja avaliado em um conjunto de teste

independente (CUNHA, 2019). A proporção relativa entre os conjuntos de treino e teste pode ser ajustada conforme necessário. Nesse contexto, é possível utilizar alguma técnica de validação cruzada, na busca de melhorar a confiabilidade da avaliação do modelo (CUNHA, 2019).

Segundo Cunha (2019) pode-se citar o método *K-Fold* (BURMAN, 1989), que consiste em dividir o conjunto de dados em K partes de tamanhos parecidos. Ocorrerão K iterações, onde uma das amostras será o conjunto de teste e as outras formarão o conjunto de treino. A cada iteração o conjunto de teste é alterado, e assim, ao final das K iterações, todos os conjuntos terão sido utilizados como teste.

Dessa forma, em vez de depender de uma única divisão dos dados em treino e teste, a validação cruzada realiza múltiplas divisões dos dados, de forma que o modelo é treinado e avaliado em diferentes subconjuntos. Essa abordagem reduz a aleatoriedade da seleção inicial dos dados de treino e teste, proporcionando uma estimativa mais robusta do desempenho do modelo (CUNHA, 2019).

Para avaliar o desempenho de cada algoritmo, podem ser utilizadas matrizes de confusão. Elas consistem em uma tabela, aonde as linhas e colunas correspondem às classes verdadeiras e preditas, conforme Tabela 3.

Tabela 3 – Matriz de confusão de um classificador

Classe	predita C_1	predita C_2	...	predita C_k
verdadeira C_1	$M(C_1, C_1)$	$M(C_1, C_2)$...	$M(C_1, C_k)$
verdadeira C_2	$M(C_2, C_1)$	$M(C_2, C_2)$...	$M(C_2, C_k)$
⋮	⋮	⋮	⋮	⋮
verdadeira C_k	$M(C_k, C_1)$	$M(C_k, C_2)$...	$M(C_k, C_k)$

Fonte: Monard e Baranauskas (2003)

Por meio da matriz de confusão é possível separar os dados classificados em 4 categorias: VP (verdadeiro positivo), VN (verdadeiro negativo), FP (falso positivo) e FN (falso negativo) (JUNIOR et al., 2022). Os verdadeiros positivos correspondem à diagonal principal da matriz de confusão e representam as amostras que foram corretamente classificadas como positivas para a respectiva classe. Os verdadeiros negativos correspondem às amostras corretamente classificadas como negativas para a respectiva classe. Estão presentes fora da linha e da coluna correspondentes à classe em questão na matriz de confusão. Os falsos positivos correspondem às amostras erroneamente classificadas como positivas quando, na verdade, são negativas. Estão presentes nas colunas das classes preditas, exceto na diagonal principal. Por fim, os falsos negativos correspondem às amostras erroneamente classificadas como negativas quando, na verdade, são positivas e estão localizados nas linhas das classes reais, exceto na diagonal principal (MONARD; BARANAUSKAS, 2003; JUNIOR et al., 2022).

Com base nos valores de VP, VN, FP e FN, é possível calcular métricas de avaliação do desempenho do modelo de classificação, destacam-se a acurácia, precisão, *recall* e *F1-Score* (JUNIOR et al., 2022).

Dentre elas, a acurácia representa a proporção de amostras corretamente classificadas em relação ao total de amostras, como pode ser observado na Equação 2.7 (JUNIOR et al., 2022).

A precisão avalia a proporção de classificações corretas em relação ao total de classificações positivas para a respectiva classe, conforme Equação 2.8 (JUNIOR et al., 2022).

O *recall* mede a proporção de amostras corretamente classificadas em relação ao total de amostras positivas para a classe analisada, conforme Equação 2.9 (JUNIOR et al., 2022).

Já o *F1-Score* combina a precisão e o *recall* para obter um valor único que representa o balanceamento entre essas duas medidas, conforme Equação 2.10 (JUNIOR et al., 2022).

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad (2.7)$$

$$Precisão = \frac{VP}{VP + FP} \quad (2.8)$$

$$Recall = \frac{VP}{VP + FN} \quad (2.9)$$

$$F1-Score = 2 \cdot \frac{Precisão \cdot Recall}{Precisão + Recall} \quad (2.10)$$

Entretanto, alta precisão no treinamento do modelo não garante bom desempenho no processamento em tempo real, pois pode ocorrer *overfitting* ou *underfitting*. O primeiro ocorre quando o modelo se ajusta demais aos dados de treinamento, apresentando alto desempenho nesta etapa, porém, ao receber novos dados, não consegue classificar corretamente. Já o segundo, ocorre quando o modelo se ajusta muito pouco aos dados de treinamento, como se o modelo não fosse capaz de capturar corretamente as relações e padrões nos dados treinados. Neste caso apresenta um desempenho ruim tanto na etapa de treinamento quanto nas etapas de validação e teste (MONARD; BARANAUSKAS, 2003).

Para corrigir isso, por exemplo, podem ser realizados ajustes nos hiperparâmetros dos modelos, como por exemplo o parâmetro C no SVM, que controla a força de regularização que o modelo terá (PEDREGOSA et al., 2011). Ou podem ser utilizados métodos de regularização, como L1 ou L2, buscando controlar o peso das *features* (VASCONCELOS, 2017). A regularização L1, também conhecida como Lasso, reduz os coeficientes de algumas características a zero enquanto destaca os coeficientes de outras, atuando como um processo de seleção de *features* (VASCONCELOS, 2017; PASSOS, 2022). Já a regularização L2,

também conhecida como *Ridge*, aplica uma penalidade relativamente homogênea aos coeficientes do modelo, mas não exclui variáveis (VASCONCELOS, 2017; PASSOS, 2022).

2.8 Trabalhos Relacionados

O sinal mioelétrico é utilizado para controle de próteses desde 1948, quando Reiter (1948) propôs o seu uso para o controle de uma mão mecânica. Posteriormente, Graupe e Cline (1975) conseguiram diferenciar 6 classes de movimentos de mão por meio de um modelo autoregressivo de média móvel. Entretanto, eram necessárias 12 horas de treinamento do usuário, o que afetava o desempenho devido à fadiga muscular. Já nos anos 90, Kelly, Parker e Scott (1990) conseguiram reduzir esse tempo por meio do uso de redes neurais artificiais e em 1993, Hudgins, Parker e Scott (1993), com um eletrodo bipolar, extraíram as características MAV, ZC, WL e também a MAVSLP (*Mean Absolute Value Slope*) e SSC(*Slope Sign Change*), e, com uma rede neural artificial de duas camadas, conseguiram classificar quatro movimentos diferentes. Entretanto, o erro foi consideravelmente alto (>10%). Foi constatado que o início da contração muscular possui uma estrutura que é diferente para movimentos de diferentes membros, o que pode ser útil para a classificação do sinal sEMG (ZECCA et al., 2002; GODOI, 2014).

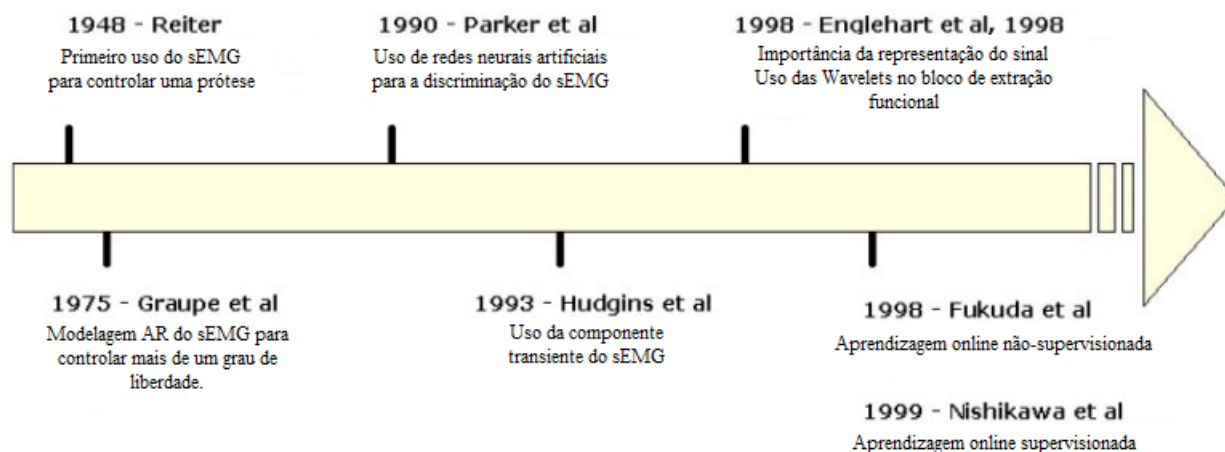
Ainda nos anos 90, Englehart (1998) desenvolveu um sistema mais complexo onde conseguiu obter menor erro que o de Hudgins. Para representar o sinal ele aplicou a transformada *wavelet* e fez uso da análise das componentes principais (PCA) e da Análise Discriminante Linear (LDA) (CUNHA et al., 2007). Assim, conseguiu melhorar a classificação e a funcionalidade do sistema, porém, as principais dificuldades referentes ao controle de próteses por sinais sEMG permaneceram: a mudança fisiológica dos músculos de indivíduo para indivíduo; mudanças no acoplamento entre a pele e os eletrodos durante o uso; característica variante no tempo e natureza estocástica que o sinal possui (ZECCA et al., 2002). A inabilidade do usuário é outro fator a ser destacado, podendo gerar erros decorrentes da operação inadequada (ZECCA et al., 2002) (GODOI, 2014). A realização de um módulo de aprendizagem *online* é uma alternativa para evitar este problema, o que foi feito inicialmente por Fukuda et al. (1998) e por Nishikawa et al. (1999).

A Figura 13 mostra a linha do tempo da evolução do sEMG como controle para a prótese de mão até o ano de 1999.

Mais recentemente, Mayor (2017) desenvolveu um método para diferenciar movimentos da mão (como flexão dos dedos, abertura e fechamento da mão e movimentos de preensão) por meio de um número reduzido de eletrodos. Extraiu características de dez amputados e comparou a classificação dos movimentos entre os métodos SVM, LDA e KNN. Percebeu que a maior precisão foi obtida com SVM, seguido por KNN e por último o LDA. Entretanto, foi verificado que o método KNN é mais rápido que o SVM, sendo mais indicado em aplicações em tempo real. Porém ainda é mais lento que o LDA.

Posteriormente, Zhou e Alici (2020) propuseram o desenvolvimento de um sistema

Figura 13 – Evolução do sEMG como Controle para Prótese de Mão



Fonte: Godoi (2014) adaptado de Zecca et al. (2002)

mioelétrico para controlar próteses de mão por reconhecimento de padrões que fosse compacto e econômico. Para isso realizaram um comparativo entre uma configuração de 4 sensores e uma de 12 sensores. Na primeira, posicionaram dois sensores sEMG-IMU (do inglês, *Inertial Measurement Unit*) no antebraço e outros dois sensores na parte superior do braço do indivíduo. Já na segunda, utilizaram 10 sensores na parte superior do braço e mantiveram os 2 sensores no antebraço. Utilizando os classificadores *Linear Discriminant Analysis* (LDA), *Convolutional Neural Network* (CNN) e *Random Forest* (RF), verificaram que a melhor precisão da primeira configuração foi obtida pelo classificador RF ($89.37\% \pm 3.19\%$), seguido pelo CNN ($87.63\% \pm 5.19\%$) e por último pelo LDA ($79.81\% \pm 4.19\%$). Percebeu-se que com o classificador RF a precisão obtida nessa configuração de 4 sensores foi próxima da configuração utilizando 12 sensores, que foi igual a $91.66\% \pm 2.28\%$. Entretanto, foi verificado que o tempo computacional para processamento do RF é 10 vezes superior ao necessário para o LDA.

Por fim, Lopes (2022) propôs o desenvolvimento e a otimização de uma prótese de membro superior controlada por sinal mioelétrico de baixo custo. Desenvolveu um método mais complexo que os anteriores, no qual coletou o sinal mioelétrico de quarenta voluntários. Os sinais foram filtrados e processados para reduzir o ruído. Em seguida, segmentou o sinal em pequenas janelas de 100 e 250 ms e foram extraídas 13 características no domínio do tempo. Para otimizar o processo, aplicou três métodos de seleção das características. Dois algoritmos de aprendizagem automática foram implementados de forma a separar a classificação em três níveis diferentes (1- se o voluntário estava em movimento ou repouso; 2- se o voluntário estava movimentando apenas um dedo ou mais que isso (preensão); 3- sendo classificado como preensão, identificava se era do tipo esférica ou em tríade). Tendo os movimentos classificados, a prótese a ser acionada foi um modelo da comunidade e-NABLE feito em impressora 3D com filamento PLA. Verificou-se que os


melhores resultados foram os que utilizaram o classificador KNN (quando $k=2$), mas para movimentos mais simples o melhor classificador foi o LDA. Além disso, obtiveram-se os melhores resultados no primeiro nível de classificação ($>90\%$), para janelas iguais a 250 ms.

3 METODOLOGIA E ETAPAS DE DESENVOLVIMENTO

3.1 Metodologia Adotada


Este trabalho tem o objetivo de acionar uma prótese de mão 3D por meio de sinais mioelétricos. Visto isso, pode-se dividir este trabalho em duas fases: A primeira, ilustrada na Figura 14, tem como objetivo o correto treinamento de um modelo de *Machine Learning* visando resolver um problema de classificação multiclasse. Já a segunda fase, representada pela Figura 15, teve como objetivo o acionamento da prótese de mão em tempo real, com base nos movimentos executados pelo usuário.

Figura 14 – Fase 1 - Treinamento do modelo de *Machine Learning*



Fonte: Produção do próprio autor.

Figura 15 – Fase 2 - Acionamento da prótese




Fonte: Produção do próprio autor.

Sendo assim, a etapa inicial foi a captura do sinal muscular e para isso foi utilizada a placa *MyoSym* (SYMBIOS, 2023), protótipo desenvolvido pela *startup* capixaba Symbios, conforme a Figura 16. A *MyoSym* é composta por um microcontrolador STM32F401ret6 ARM Cortex-M4 (ST, 2015), que possui uma capacidade de 96 kb de memória RAM e 512 kb de memória Flash. Adicionalmente, é integrado um estágio de pré-amplificação responsável por aumentar a amplitude do sinal inicialmente capturado. Ela também possui o *analog front-end* ADS1293 (TI, 2014) para conversão analógico/digital, que possui 24 bits de resolução. Além disso, são disponibilizados 3 canais bipolares, os quais são conectados aos eletrodos adesivos de superfície por meio de fios eletrodos. Conforme discutido na Seção 2.5, a utilização de canais bipolares é crucial para eliminar o ruído comum aos dois eletrodos do canal. Contudo, deve-se considerar que a utilização de fios pode aumentar

a suscetibilidade a ruídos e ao fenômeno denominado *crosstalk*. A *MyoSymb* apresenta dois modos de operação distintos. No primeiro modo, ela é configurada para coletar e armazenar os dados em um cartão SD (do inglês, *Secure Digital Card*) durante o período de tempo determinado. Já no segundo modo, é configurada para enviar os dados de forma contínua por meio da porta serial via USB (*Universal Serial Bus*). Em ambos os casos, com o intuito de evitar perdas de informação, uma taxa de amostragem de 1000 Hz foi estabelecida, conforme mencionado na Seção 2.4.

Figura 16 – *MyoSymb* (Symbios)




Fonte: Produção do próprio autor.

A captura dos dados foi realizada com os 3 canais posicionados conforme a Figura 17 no antebraço do usuário, que executou movimentos de flexão e extensão dos dedos (conforme a Figura 1) e também o movimento de pinça, correspondente a fechar os dedos indicador, médio e polegar.

Visando assegurar a consistência na coleta dos dados, foi estabelecido um protocolo de padronização das condições. Nesse sentido, definiu-se que a palma da mão seria posicionada sempre voltada para cima e o braço seria adequadamente apoiado para garantir a estabilidade, minimizando quaisquer variações de movimento indesejadas. Adicionalmente, foram executadas etapas de preparação, como a remoção dos pelos e a higienização da superfície da pele onde os sensores foram fixados, utilizando álcool 70%.

Além disso, para a primeira fase foi adotado um protocolo para a coleta dos dados, no qual estabeleceu-se o tempo de 60 s para cada sessão de captura. Durante esse período, o participante permanece em repouso nos primeiros 5 s e, em seguida, executa o movimento específico nos 5 s subsequentes, repetindo esse ciclo até completar o tempo total. Esse procedimento foi realizado separadamente para cada um dos três movimentos selecionados, conforme detalhado na Tabela 4.

Figura 17 – Posição dos 3 canais no antebraço do usuário



Fonte: Produção do próprio autor.

Tabela 4 – Protocolo de Captura dos Dados

Tempo de Captura	Segundos	Movimentos Executados		
		Flexão dos Dedos	Extensão dos Dedos	Movimento de Pinça
1 min	0-5	relaxa	relaxa	relaxa
	5-10	executa	executa	executa
	10-15	relaxa	relaxa	relaxa
	15-20	executa	executa	executa
	20-25	relaxa	relaxa	relaxa
	25-30	executa	executa	executa
	30-35	relaxa	relaxa	relaxa
	35-40	executa	executa	executa
	40-45	relaxa	relaxa	relaxa
	45-50	executa	executa	executa
	50-55	relaxa	relaxa	relaxa
	55-60	executa	executa	executa

Fonte: Produção do próprio autor.

Nesta etapa durante a Fase 1, a *MyoSym* foi configurada para o modo captura, salvando os dados em mV no cartão SD, no formato CSV (do inglês, *comma separated values*).

Dessa forma, procedeu-se com o pré-processamento dos dados, com o objetivo de realizar o tratamento e remover possíveis interferências. Nesse contexto, foram aplicados

dois tipos de filtragem. Primeiramente, utilizou-se um filtro *Butterworth* como passa-bandas, com uma faixa de frequência de 20 Hz a 450 Hz. Em seguida, empregou-se um filtro *Notch* para reduzir uma possível interferência da frequência da rede elétrica de 60 Hz presente no sinal. Esses procedimentos de filtragem foram adotados visando aprimorar a qualidade dos dados coletados.

A etapa seguinte foi a extração das características, visando distinguir os padrões de movimento por meio de métodos matemáticos. Para isso foram selecionadas as características RMS, WL, ZC, SSI, MAV e VAR representadas pelas Equações 2.1, 2.2, 2.3, 2.4, 2.5 e 2.6 conforme discutido na Seção 2.6.

Esses cálculos foram realizados utilizando uma técnica chamada janelamento, que consiste em dividir o sinal em segmentos mais curtos e sobrepostos. Esses segmentos são chamados de janelas e possuem um tamanho fixo, determinado pela duração desejada para análise. As janelas são deslizadas ao longo do sinal original com um determinado passo, gerando uma sobreposição entre os segmentos, o que permite capturar informações temporais em diferentes partes do sinal (SOUZA, 2021).

Souza (2021) testou diferentes valores para o tamanho da janela e diferentes valores de sobreposição e concluiu que o melhor resultado encontrado foi de 200 ms e 100 ms, respectivamente.

Sendo assim, neste trabalho foi estabelecido o tamanho da janela igual a 200 ms, o que corresponde a 200 amostras. Logo, nas Equações 2.1, 2.2, 2.3, 2.4, 2.5 e 2.6, a variável N possui valor igual a 200. Além disso, adotou-se um passo de sobreposição, também conhecido como *overlapping*, equivalente a 50% do tamanho da janela, ou seja, 100 amostras. Isso significa que a realização dos cálculos sucessivos envolveu segmentos sobrepostos de 100 amostras entre si.

Para ilustrar, o primeiro cálculo foi realizado considerando as amostras da posição 1 até a posição 200, o segundo cálculo considerou as amostras da posição 101 até a posição 300, o terceiro cálculo considerou as amostras da posição 201 até a posição 400, e assim por diante.

Posteriormente, deu-se início à etapa de rotulagem dos dados, na qual são atribuídos rótulos/classes às amostras de dados. A correta rotulagem desempenha um papel crucial na classificação dos algoritmos de Aprendizado de Máquina, já que é com base nisso que o modelo irá aprender a classificar novos dados. Nesse contexto, foram estabelecidas quatro classes, sendo que cada uma foi representada por um número correspondente: 1) Relaxado; 2) Flexão; 3) Extensão; e 4) Pinça.

Visando evitar a atribuição de rótulos incorretos, adotou-se uma estratégia de exclusão dos primeiro e último segundos de cada intervalo de captura de 5 s. Essa abordagem baseia-se na possibilidade de o usuário iniciar o movimento ligeiramente antes ou depois do instante exato durante a coleta dos dados. Portanto, ao realizar esse ajuste, buscou-se ampliar a fidedignidade dos dados que serão fornecidos ao modelo de

Aprendizado de Máquina, garantindo uma informação mais precisa e confiável para o processo de treinamento e classificação.

Além disso, de acordo com o protocolo de coleta de dados estabelecido, observou-se que a classe "1 - Relaxado" apresentou uma frequência maior, totalizando 540 amostras, enquanto as demais classes registraram 180 amostras cada. Sendo assim, com o intuito de alcançar um equilíbrio entre todas as classes, procedeu-se com a exclusão aleatória de 360 amostras da classe "1 - Relaxado". Essa estratégia teve como objetivo equalizar o número de amostras disponíveis para cada classe, promovendo um conjunto de dados balanceado e visando garantir a imparcialidade e a efetividade do modelo na análise e classificação de todas as classes.

Por fim, prosseguiu-se para o treinamento do modelo de aprendizado de máquina. Foram escolhidos os algoritmos KNN, SVM, LDA e RF, já que conforme visto nas Seções 2.7 e 2.8, são algoritmos capazes de resolver problemas de classificação e comumente empregados em aplicações que envolvam eletromiografia (LOPES, 2022; MAYOR, 2017; ZHOU; ALICI, 2020).

Para todos os algoritmos, 70% dos dados foram utilizados para treinamento do modelo, enquanto que 30% foram utilizados para teste do modelo. Conforme discutido na Seção 2.7, com o objetivo de analisar o treinamento do modelo, foram geradas matrizes de confusão e também calculadas métricas comumente utilizadas em problemas de classificação (JUNIOR et al., 2022). São elas: acurácia, precisão, *recall* e *F1-Score* conforme as Equações 2.7, 2.8, 2.9 e 2.10, respectivamente. Os valores obtidos, assim como as matrizes de confusão, podem ser observados na Seção 4.3.

Após o treinamento do modelo, avançou-se para o desenvolvimento do algoritmo de controle em tempo real para a ativação da prótese, dando início à Fase 2, representada pela Figura 15.

A prótese de mão, representada na Figura 18, foi feita por meio de impressão 3D com filamento de PLA (Ácido poliláctico, em inglês *Polylactic Acid*), com base no projeto *open-source* da empresa InMoov (INMOOV, 2014) e é composta por servomotores que, ao serem acionados, tracionam linhas responsáveis por abrir/fechar os dedos mecânicos.


Para o acionamento em tempo real, a *MyoSym* foi configurada no modo *serial*, enviando continuamente os dados pela porta serial via USB a uma taxa de 1000 Hz.

Visto isso, o algoritmo foi projetado para armazenar os dados em uma variável, até que 1000 amostras fossem capturadas, correspondendo a 1 s de captura. Em seguida, os processos de filtragem e extração de características foram aplicados, seguindo a mesma metodologia utilizada no treinamento do modelo.

Posteriormente, o modelo de aprendizado de máquina, classifica as amostras recebidas e determina a classe mais frequente para o respectivo segundo de captura. Com base nessa classificação, é enviado um comando para acionar os motores da prótese.

Para o acionamento, um Arduino UNO (ARDUINO, 2010) foi utilizado e conectado

Figura 18 – Prótese de mão feita em impressora 3D



Fonte: Produção do próprio autor.


a outra porta serial via USB. Ele recebe a informação sobre qual servomotor deve ser acionado e o ângulo correspondente, resultando nos movimentos de flexão, extensão e pinça. Por outro lado, a classe "Relaxado" não provoca alterações na posição dos servomotores.

Para fornecer a corrente necessária aos servomotores, foi empregado o módulo PCA9685 (ADAFRUIT, 2015). Esse módulo possui a capacidade de controlar até 16 servomotores utilizando a técnica de modulação PWM (do inglês, *Pulse Width Modulation*), e se comunica com o Arduino por meio do protocolo I2C (do inglês, *Inter-Integrated Circuit*). Além disso, para a alimentação desse módulo, foi utilizada uma bateria de 24 V em conjunto com um regulador de tensão LM2596 (TI, 1999) que abaixa a saída para 5 V, pois os servos são alimentados com este valor. O esquemático de conexão pode ser visualizado na Figura 19, onde as conexões foram realizadas por fios.

Para avaliar a efetividade do processamento em tempo real, foi elaborado um protocolo de teste, conforme representado na Tabela 5. Neste protocolo, definiu-se que o usuário deve executar o movimento de cada classe por 10 classificações consecutivas. Após ter feito todos os movimentos, repetir o processo, de forma a totalizar 20 classificações.

Com base nas classificações realizadas pelo algoritmo em comparação com o executado pelo usuário, foi possível construir as matrizes de confusão para cada movimento e calcular as métricas de desempenho, seguindo a mesma abordagem empregada na primeira fase do estudo. Os valores obtidos, assim como as matrizes de confusão, podem ser observados na Seção 4.4.

Figura 19 – Esquemático de ligação do sistema para controle da prótese



Fonte: Produção do próprio autor.

Tabela 5 – Protocolo de Teste da Classificação em Tempo Real

Movimento a ser executado	Número de classificações a serem observadas
Relaxado	10
Flexão	10
Extensão	10
Pinça	10
Relaxado	10
Flexão	10
Extensão	10
Pinça	10

Fonte: Produção do próprio autor.

4 RESULTADOS E DISCUSSÃO

Este capítulo tem como objetivo apresentar e discutir os resultados obtidos por meio da análise dos dados coletados durante o desenvolvimento deste trabalho. Eles serão apresentados de acordo com a estrutura organizada em quatro etapas principais: pré-processamento dos dados, extração de características, treinamento do modelo e processamento em tempo real.

Primeiramente, serão descritos os resultados do pré-processamento, no qual foram aplicados filtros para tratar os dados brutos e minimizar possíveis interferências.

Em seguida, serão apresentados os resultados da etapa de extração de características, na qual foram identificadas e selecionadas as características mais relevantes dos dados para a análise subsequente.

Posteriormente, serão abordados os resultados da classificação durante o treinamento do modelo, utilizando algoritmos de aprendizado de máquina. Serão apresentados os resultados das métricas de desempenho, como acurácia, precisão, *recall* e *F1-score*, para cada um dos modelos avaliados. Também serão discutidas as matrizes de confusão, permitindo uma análise mais detalhada da capacidade dos modelos em distinguir corretamente as diferentes classes.

E por fim será analisado o processamento em tempo real, buscando analisar a classificação em tempo real e verificar a viabilidade e a eficiência do algoritmo desenvolvido para o acionamento da prótese.

4.1 Pré-processamento dos Dados

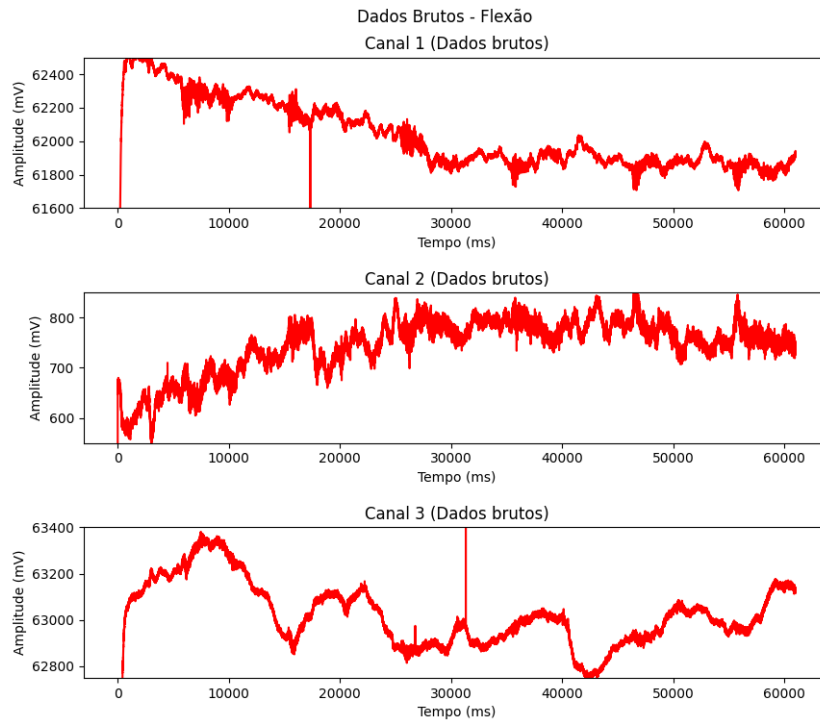
O objetivo dessa etapa foi realizar o tratamento adequado dos sinais brutos, removendo interferências indesejadas e preparando os dados para as etapas subsequentes da análise. Vale ressaltar que os sinais mioelétricos foram adquiridos a uma taxa de amostragem de 1000 Hz e apresentam uma resolução de 24 bits, de acordo com o ADS1293 (TI, 2014) utilizado na *MyoSym* (SYMBIOS, 2023).

Para remover as interferências indesejadas presentes nos sinais brutos, foram aplicados filtros digitais. Inicialmente, utilizou-se um filtro Butterworth passa-banda com frequência de corte inferior de 20 Hz e frequência de corte superior de 450 Hz. Essas frequências foram selecionadas de acordo com as características do sinal mioelétrico, conforme discutido na Seção 2.4. Em seguida, foi aplicado um filtro Notch com frequência de corte em 60 Hz, com o objetivo de reduzir a interferência da rede no sinal capturado.

As Figuras 20, 22 e 24 mostram os sinais brutos dos movimentos de flexão, extensão e pinça, respectivamente. Enquanto as Figuras 21, 23 e 25 mostram esses sinais filtrados.

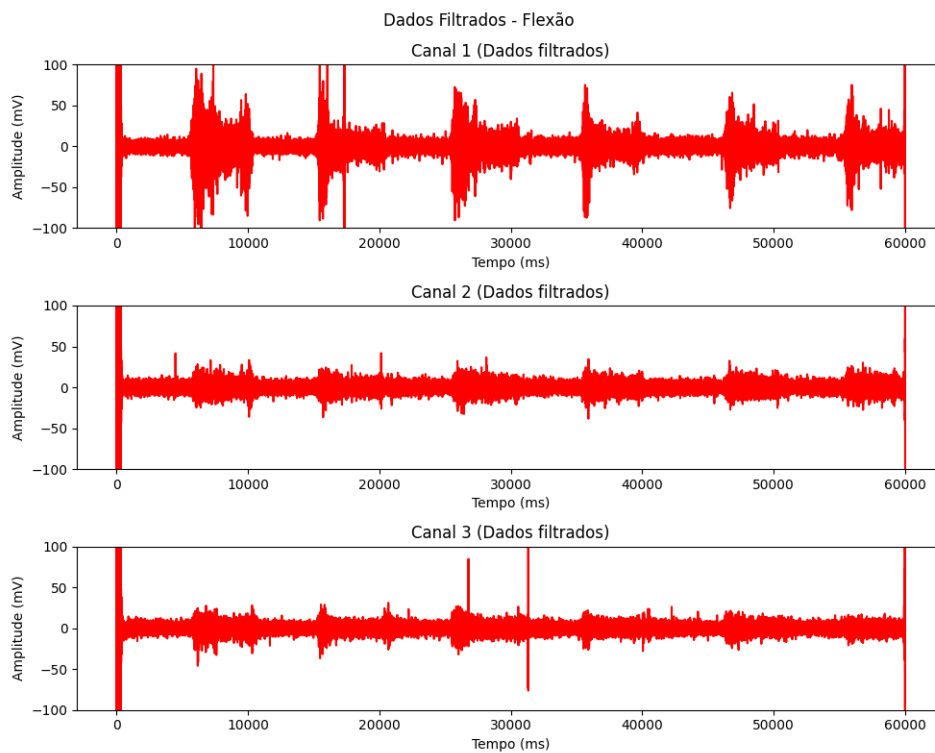
Ao analisar a amplitude dos sinais após o pré-processamento, verificou-se uma notável redução nos ruídos e uma maior normalização do sinal. Essas melhorias são claramente observadas nas imagens dos sinais filtrados, especialmente durante os momentos de contração muscular. Essa visualização detalhada e a identificação de padrões de atividade muscular eram dificultadas ou até mesmo impossibilitadas nos dados brutos iniciais. Esses resultados evidenciam a eficácia da etapa de pré-processamento dos dados, contribuindo para uma melhor interpretação e análise dos sinais mioelétricos.

Figura 20 – Sinal Bruto - Flexão



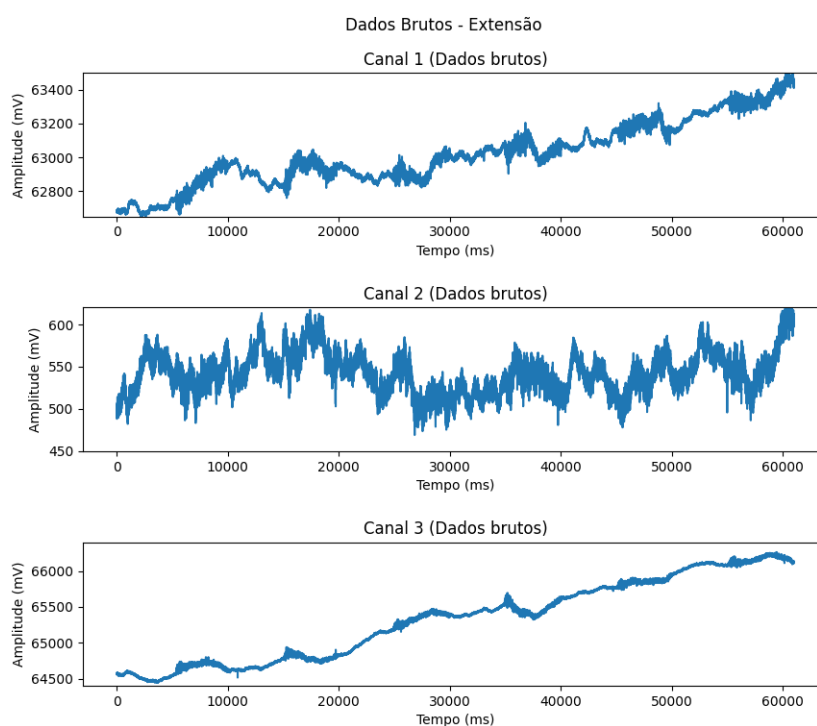
Fonte: Produção do próprio autor.

Figura 21 – Sinal Filtrado - Flexão



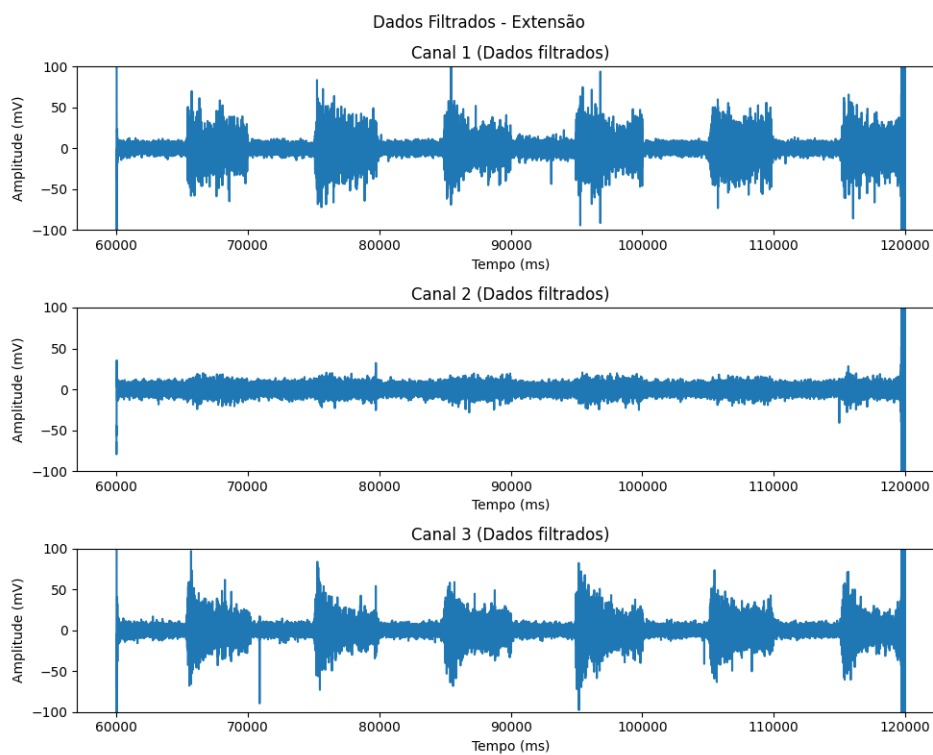
Fonte: Produção do próprio autor.

Figura 22 – Sinal Bruto - Extensão



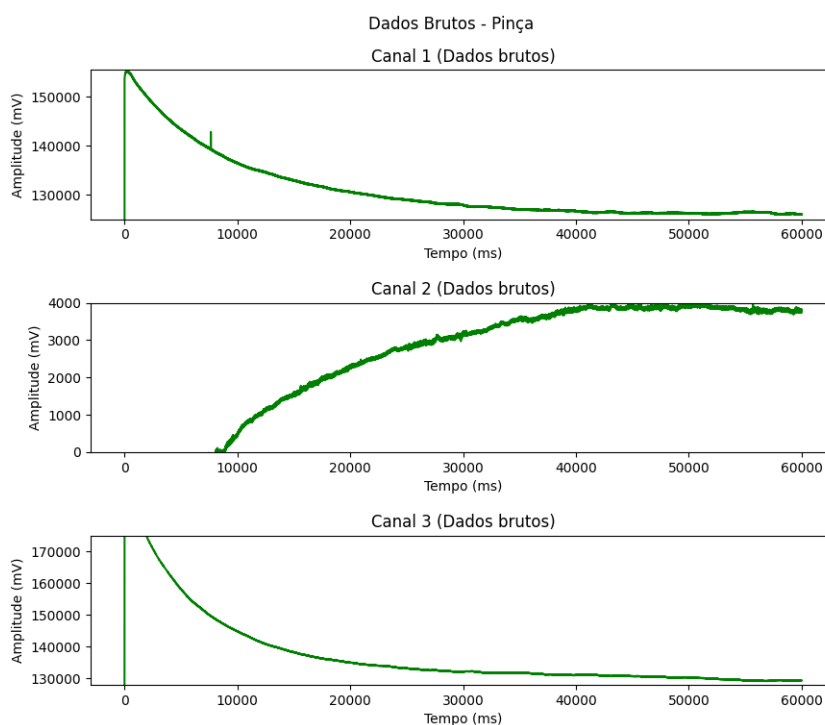
Fonte: Produção do próprio autor.

Figura 23 – Sinal Filtrado - Extensão



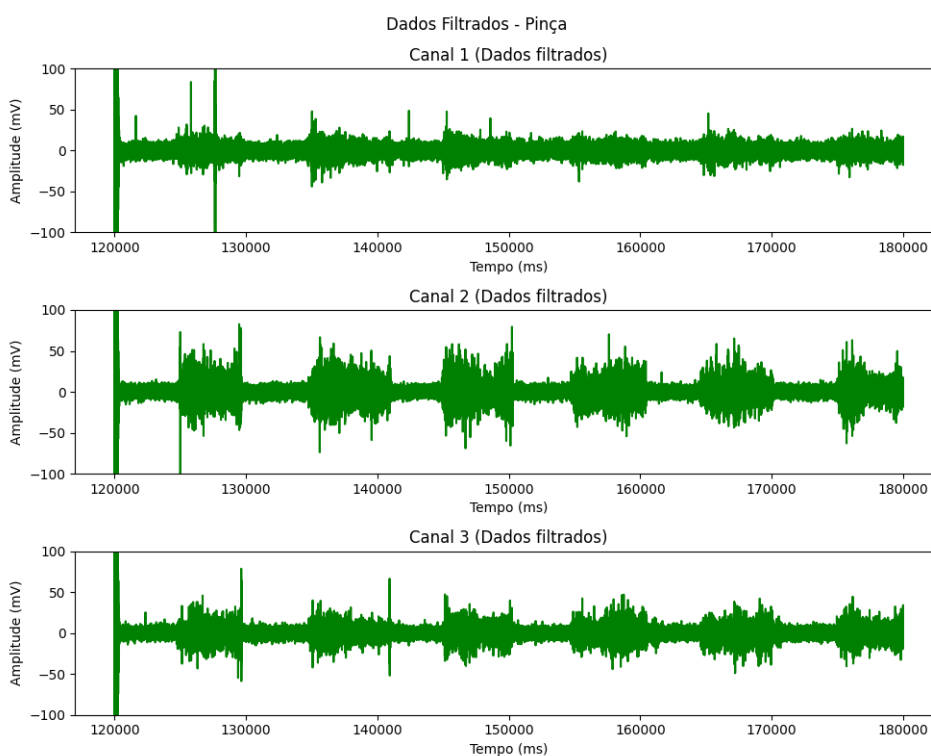
Fonte: Produção do próprio autor.

Figura 24 – Sinal Bruto - Pinça



Fonte: Produção do próprio autor.

Figura 25 – Sinal Filtrado - Pinça



Fonte: Produção do próprio autor.

4.2 Extração de Características

Nesta etapa de extração de características dos sinais mioelétricos, foram utilizadas seis características (em inglês, *features*) comumente empregadas na análise de sinais sEMG conforme discutido na Seção 2.6: RMS (*Root Mean Square*), WL (*Waveform Length*), ZC (*Zero Crossing*), SSI (*Simple Square Integral*), MAV (*Mean Absolute Value*) e VAR (*Variance*) conforme equações 2.1, 2.2, 2.3, 2.4, 2.5 e 2.6, respectivamente.

Essas características extraídas são fundamentais para compreender e distinguir os padrões presentes nos sinais mioelétricos adquiridos durante o experimento. Através delas, é possível extrair informações relevantes sobre a amplitude, forma de onda, mudanças de polaridade, energia e potência dos sinais, contribuindo para a identificação e classificação dos diferentes movimentos executados.

Para visualização e análise dos resultados, foram gerados gráficos para as 6 características mencionadas para os 3 canais da *MyoSym*. As Figuras 26, 27 e 28 mostram o resultado das *features* durante a captura da Flexão, Extensão e Pinça, respectivamente, conforme protocolo estabelecido na Seção 3.1.

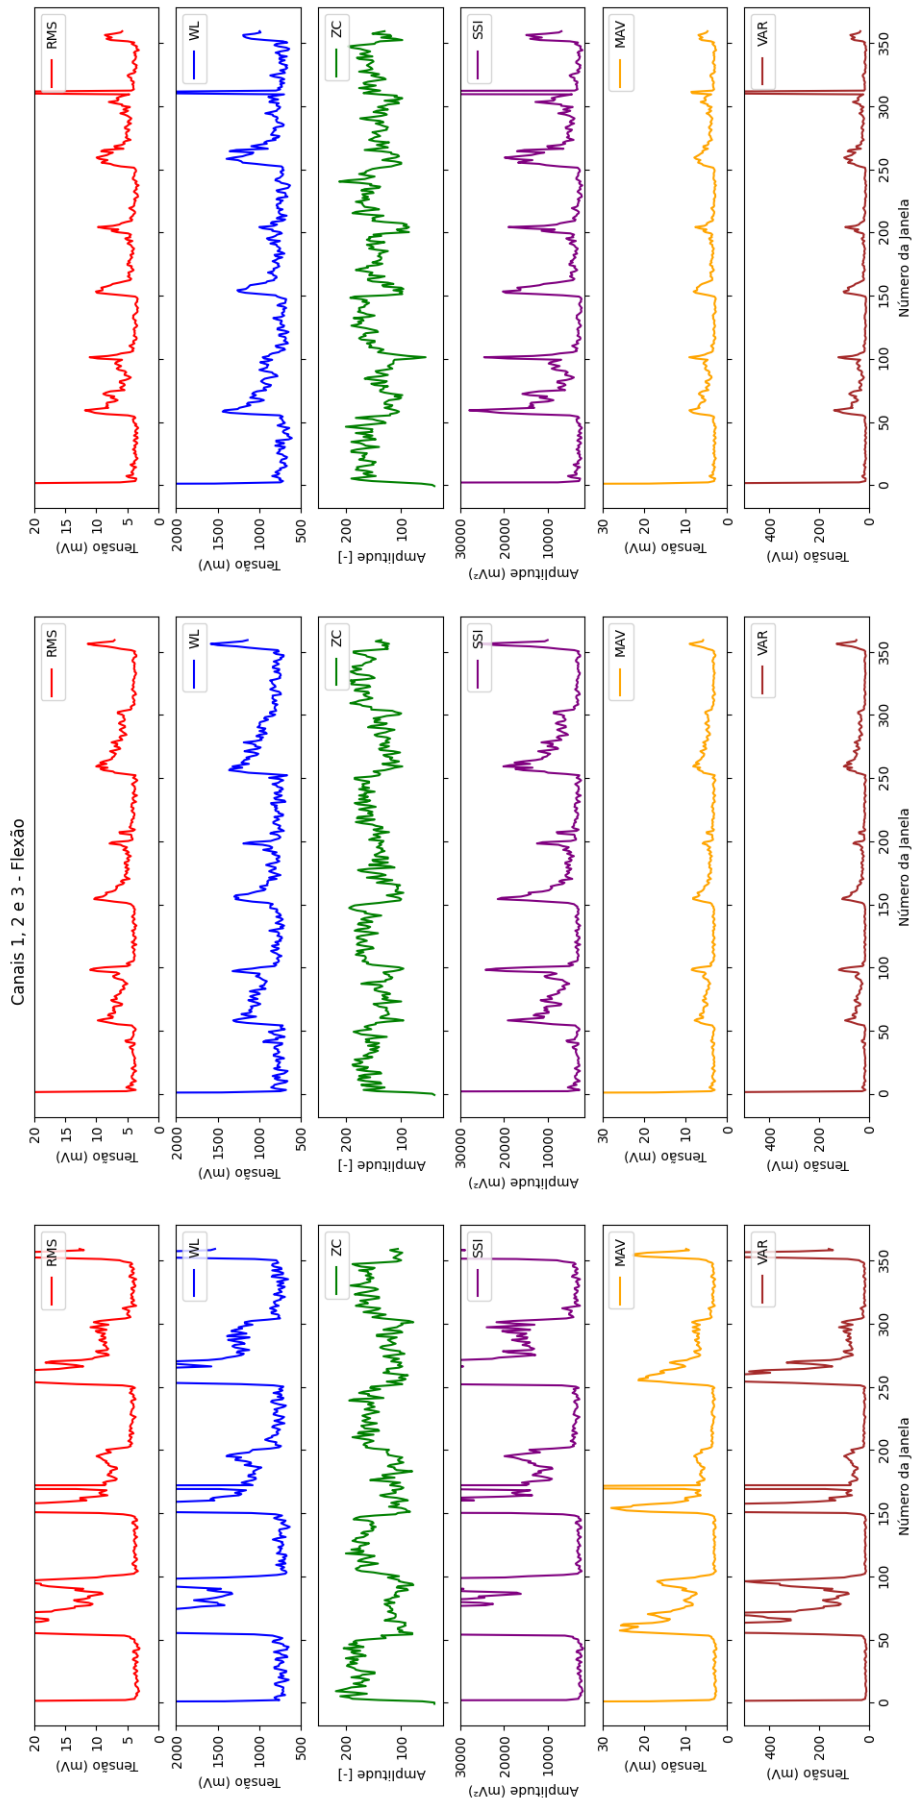
O eixo vertical dos gráficos traz a amplitude de cada característica, enquanto que o eixo horizontal traz o correspondente número da janela, pois como discutido na Seção 3.1, as *features* foram calculadas utilizando a técnica de janelamento, na qual o tamanho da janela foi definido em 200 amostras, com *overlapping* de 50%, o que significa dizer que houve sobreposição de dados a cada 100 amostras, conforme detalhado na Seção 3.1.

A análise desses gráficos permite visualizar as variações e tendências presentes em cada característica, destacando as diferenças entre os movimentos realizados.

Nota-se um aumento na amplitude das características nos momentos de contração muscular, com exceção da *feature Zero Crossing*, que apresenta uma redução na amplitude. Esse comportamento é devido à diminuição da frequência de cruzamento dos zeros quando a amplitude está alta. Além disso, é possível observar que alguns canais são mais ativados de acordo com o movimento executado.

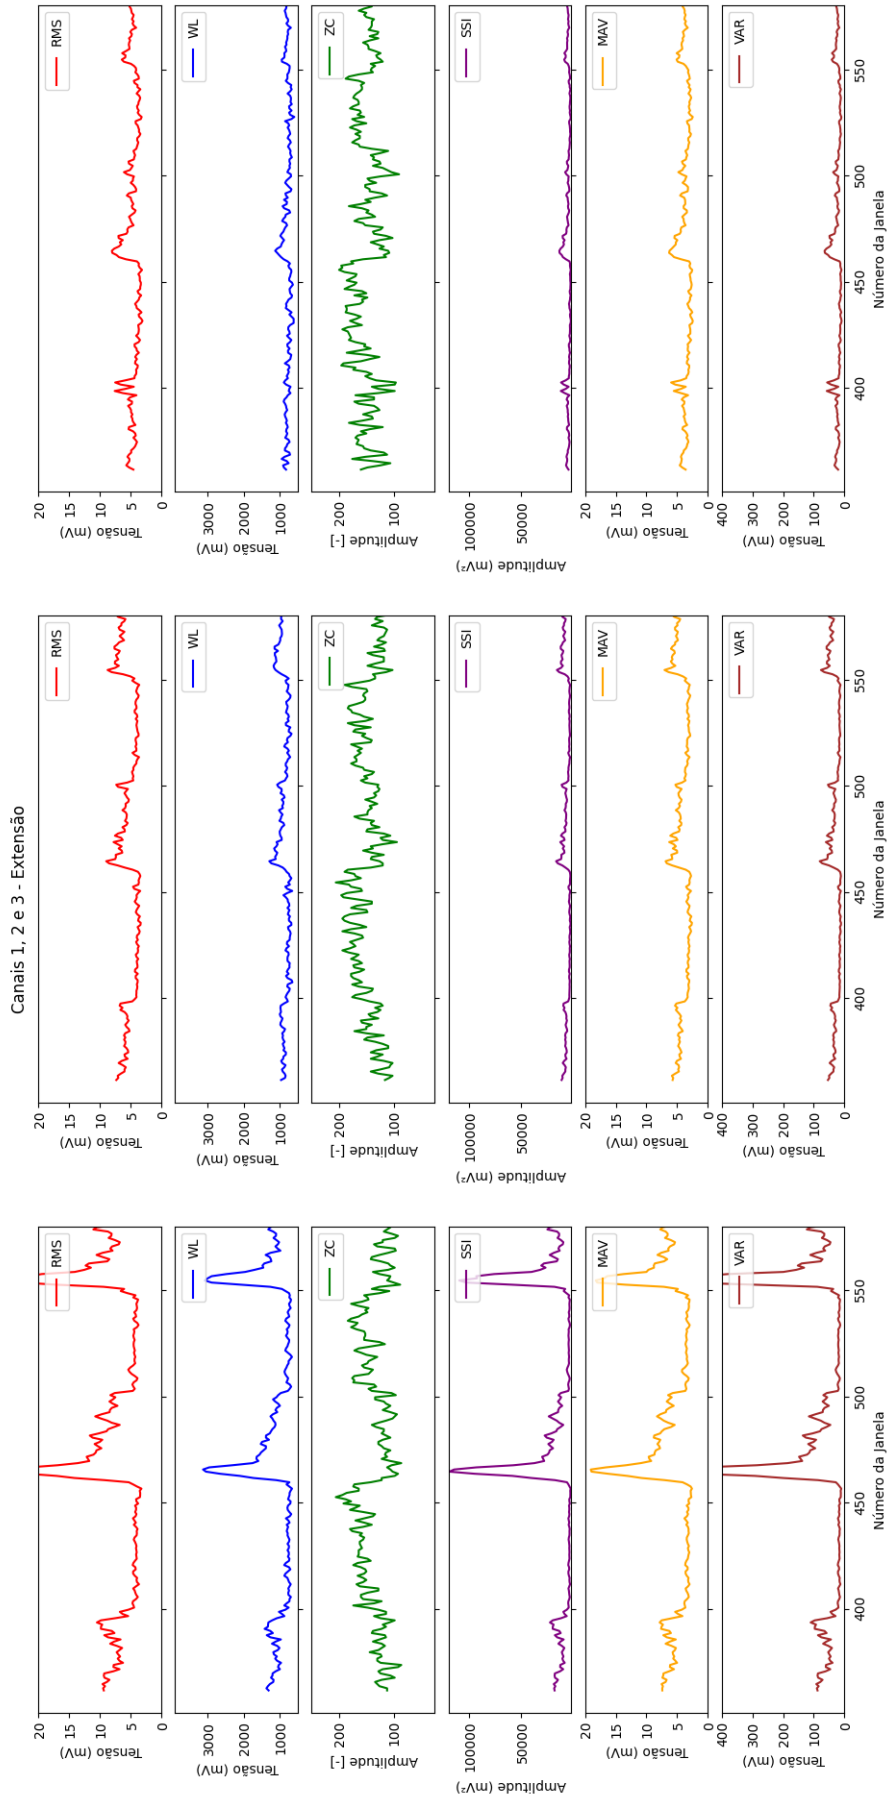
Essas informações serão utilizadas na próxima etapa para a classificação e acionamento da prótese de acordo com os padrões identificados.

Figura 26 – Características extraídas durante a captura da Flexão



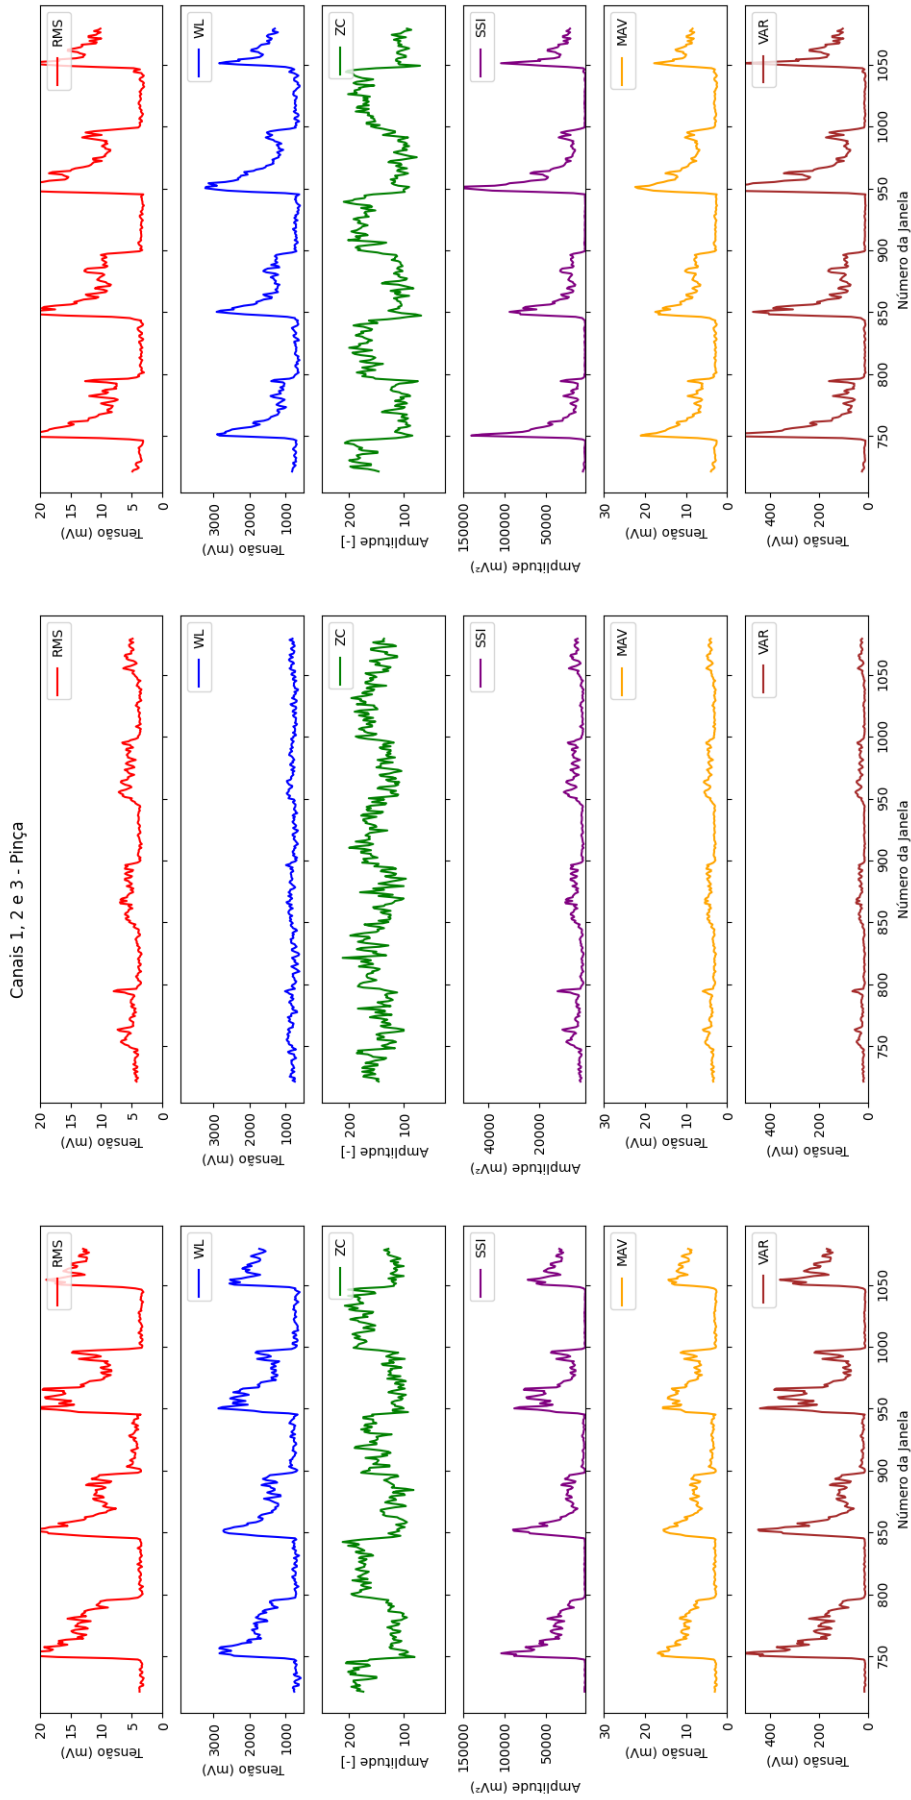
Fonte: Produção do próprio autor.

Figura 27 – Características extraídas durante a captura da Extensão



Fonte: Produção do próprio autor.

Figura 28 – Características extraídas durante a captura da Pinça



Fonte: Produção do próprio autor.

4.3 Treinamento do Modelo e Classificação

Nesta etapa, realizou-se a classificação dos padrões mioelétricos utilizando dois algoritmos amplamente utilizados em problemas de classificação, conforme discutido nas seções 2.7 e 2.8: KNN (*K-Nearest Neighbors*) e SVM (*Support Vector Machines*). Também foram realizados testes com o LDA (*Linear Discriminant Analysis*) e RF (*Random Forest*), mas não houve êxito na classificação em tempo real, conforme será discutido ao longo desta seção.

O objetivo da comparação entre os modelos foi avaliar o desempenho de cada algoritmo na identificação dos movimentos realizados.

Para a avaliação dos resultados, foram utilizadas métricas comumente empregadas na análise de classificação, como acurácia, precisão, *recall* e *F1-score*, conforme discutido na Seção 2.7. Além disso, foram geradas matrizes de confusão para visualizar a distribuição das classificações realizadas pelos algoritmos.

Durante o treinamento dos algoritmos, foi necessário ajustar os hiperparâmetros para evitar problemas de *overfitting* ou *underfitting*. Como discutido na Seção 2.7, o primeiro ocorre quando o modelo se ajusta demais aos dados de treinamento, apresentando alto desempenho nesta etapa, porém, ao receber novos dados, não consegue classificar corretamente. Já o segundo, ocorre quando o modelo se ajusta muito pouco aos dados de treinamento, como se o modelo não fosse capaz de capturar corretamente as relações e padrões nos dados treinados. Neste caso apresenta um desempenho ruim tanto na etapa de treinamento quanto nas etapas de validação e teste. (MONARD; BARANAUSKAS, 2003).

Observou-se que em alguns casos ocorreu *overfitting*, pois os algoritmos apresentavam altíssima acurácia durante a fase de treinamento, porém, quando novos dados eram fornecidos no processo de classificação em tempo real, o classificador demonstrava insensibilidade à entrada.

Para evitar esse problema, foram adotadas estratégias como ajustes nos hiperparâmetros dos modelos, seleção de características e a aplicação de métodos de regularização, como L1 ou L2, conforme Seção 2.7, para controlar o peso das *features*. Essas medidas contribuíram para melhorar a generalização do modelo, tornando-o mais eficiente na classificação de dados não contemplados anteriormente.

Visto isso, as métricas citadas nesta seção já estão considerando todos esses ajustes visando um bom funcionamento do algoritmo em tempo real, pois durante os testes realizados, observou-se que era possível obter valores mais altos de acurácia durante o treinamento. No entanto, ao realizar o processamento *online*, os resultados não eram consistentes e precisos.

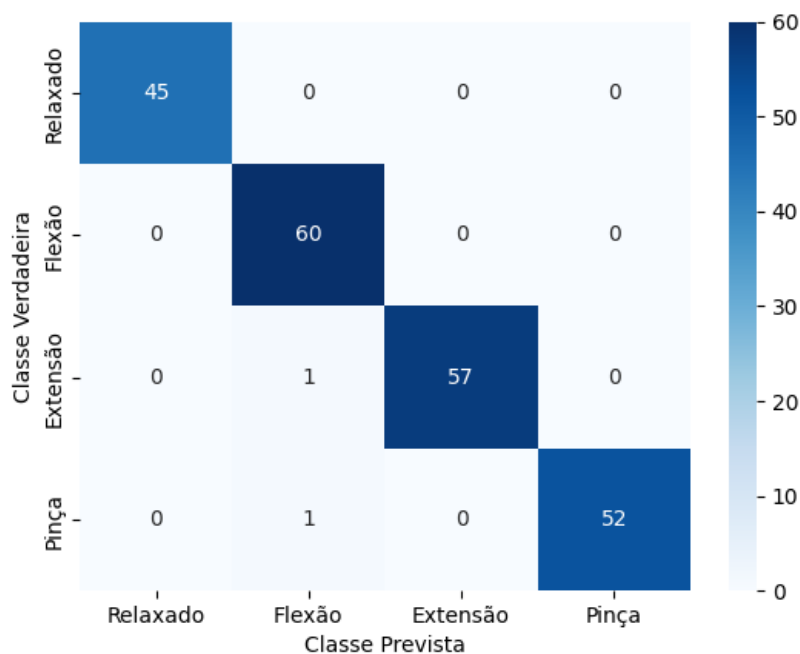
Portanto, sobre o modelo KNN, o melhor resultado encontrado foi utilizando todas as 6 *features* citadas na seção anterior, não sendo necessários nenhuma regularização ou ajuste dos hiperparâmetros, resultando numa acurácia de $98,06 \pm 1,42$ %.

Este valor foi obtido realizando a técnica de validação cruzada *K-Fold* (conforme discutido na Seção 2.7) na qual o conjunto de dados foi dividido em 5 partições. Em cada iteração, 4 partições foram utilizadas para treinamento do modelo e a partição restante foi reservada para teste. Esse processo foi repetido 5 vezes, de forma que todas as partições foram utilizadas como conjunto de teste em uma das iterações.

A técnica de validação cruzada foi utilizada buscando estimar o desempenho do modelo de forma mais confiável, já que essa técnica permite avaliar o desempenho do modelo em diferentes conjuntos de dados de teste (CUNHA, 2019).

O valor 98,06% representa a média da acurácia obtida através das iterações da validação cruzada. Já o valor 1,42% representa o desvio padrão, que indica a variabilidade da acurácia entre as diferentes partições de teste.

Figura 29 – Matriz de Confusão - KNN



Fonte: Produção do próprio autor.

A matriz de confusão relativa a este modelo está representada na Figura 29.

Ao analisar a matriz, é possível observar a diagonal principal, que representa as amostras corretamente classificadas como verdadeiros positivos. Nesse contexto, verifica-se que todas as 45 amostras da classe "Relaxado" foram classificadas corretamente, assim como as amostras da classe "Flexão". Em relação às 58 amostras da classe "Extensão", apenas uma foi erroneamente classificada como "Flexão". O mesmo ocorreu com as 54 amostras da classe "Pinça", em que somente uma foi incorretamente classificada, também como "Flexão".

Os resultados obtidos indicam que o modelo KNN apresentou um desempenho consistente e promissor na tarefa de classificação. A alta acurácia obtida reflete a capacidade

do modelo em classificar corretamente a maioria das instâncias do conjunto de dados. Além disso, a baixa variabilidade, demonstrada pelo baixo desvio padrão, sugere que o modelo é robusto e não sofreu influência significativa da escolha das partições de teste.

No entanto, é importante ressaltar que, mesmo com resultados satisfatórios, isso não garante que o desempenho do modelo KNN seja reproduzido no processamento *online* com novos dados. Foi observado que os algoritmos LDA e RF, embora tenham sido treinados com alta acurácia, não conseguiram classificar corretamente os novos dados durante o processamento *online*. Diversos ajustes foram realizados, como a seleção de *features* e a variação dos hiperparâmetros, mas não foi possível corrigir esses modelos para alcançar as classificações desejadas em tempo real.


Essa limitação ocorre porque nem sempre um determinado modelo se adequará perfeitamente ao problema proposto, sendo necessário explorar diferentes modelos e técnicas para encontrar a abordagem mais adequada. No caso dos modelos LDA e RF, pode ser necessário adotar uma abordagem diferente na metodologia, a fim de garantir que eles se ajustem corretamente aos requisitos do problema. Isso pode envolver a exploração de diferentes estratégias de regularização ou até mesmo a reformulação da abordagem geral para atender às necessidades desses modelos.

Já para o SVM foi obtida uma acurácia de 97,22%. Mas para este modelo não foi possível utilizar a validação cruzada. Por exigir um processamento computacional significativo, o algoritmo ficou em execução por horas e não retornou o resultado para as partições. Sendo assim, os dados foram separados de forma aleatória em 70% para treinamento e 30% para teste. Para que a classificação em tempo real fosse correta, foram necessários ajustes no modelo. Neste caso apenas as características RMS, ZC e SSI foram selecionadas. Além disso, foi realizado um ajuste no hiperparâmetro C, o qual segundo Pedregosa et al. (2011), controla a força da regularização do modelo SVM.

Este parâmetro pode ser visto como uma penalização que é imposta ao modelo durante o treinamento para cada amostra classificada erroneamente e pode assumir valores entre 0 e 1 (PEDREGOSA et al., 2011; REMIGIO, 2020). Assim, um alto valor de C faz com que o algoritmo treine o modelo em busca da separação completa entre as classes. Em contrapartida, baixos valores de C flexibilizam a etapa de treinamento e permitem fronteiras de decisão com erros (PEDREGOSA et al., 2011; REMIGIO, 2020). É necessário buscar um equilíbrio, para que não gere *overfitting* ou *underfitting*, como discutido na Seção 2.7. Este parâmetro foi ajustado como igual a 0,8, pois este valor foi o que apresentou melhor desempenho durante os testes realizados.

A matriz de confusão referente ao modelo SVM encontra-se representada na Figura 30. É possível verificar que as 47 amostras pertencentes à classe "Relaxado" foram corretamente classificadas. Em relação à classe "Flexão", foram identificadas incorretamente 4 amostras, sendo duas classificadas erroneamente como "Relaxado" e duas como "Pinça". Quanto às classes "Extensão" e "Pinça", foi observado um único caso de classificação incorreta, onde

Figura 30 – Matriz de Confusão - SVM



Fonte: Produção do próprio autor.

Tabela 6 – Métricas de Desempenho - Classificação

		Acurácia	Precisão	Recall	F1-Score
KNN	Relaxado	98,06 +/- 1,42 %	100 %	100 %	99,08%
	Flexão		96,77%	100 %	
	Extensão		100 %	98,28%	
	Pinça		100 %	98,11%	
SVM	Relaxado	97,22 %	95,92%	100%	97,21%
	Flexão		96,36%	92,98%	
	Extensão		100%	98,21%	
	Pinça		96,49%	98,21%	

Fonte: Produção do próprio autor.

uma amostra de cada classe, dentre as 56 existentes, foi equivocadamente classificada como "Flexão".

Por fim, para permitir uma análise comparativa dos algoritmos utilizados, as métricas de desempenho, incluindo acurácia, precisão, *recall* e *F1-score*, estão apresentadas na Tabela 6.

4.4 Processamento em Tempo Real

Nesta etapa, foi realizado o processamento em tempo real dos sinais mioelétricos, utilizando os algoritmos de classificação desenvolvidos previamente. O objetivo foi avaliar a efetividade do sistema na identificação dos movimentos e no acionamento da prótese de forma dinâmica.

Para medir a efetividade do processamento *online*, foi definido um protocolo de teste, conforme Tabela 5, no qual foi estabelecido que o usuário deve realizar o respectivo movimento durante 10 classificações e repetir o processo, totalizando 20 classificações para cada classe. Com base no que é retornado pelo algoritmo, pôde-se calcular as métricas de desempenho, conforme representado na Tabela 7. Além disso, também foi possível obter as matrizes de confusão, que podem ser observadas nas Figuras 31 e 32 para os modelos KNN e SVM, respectivamente.

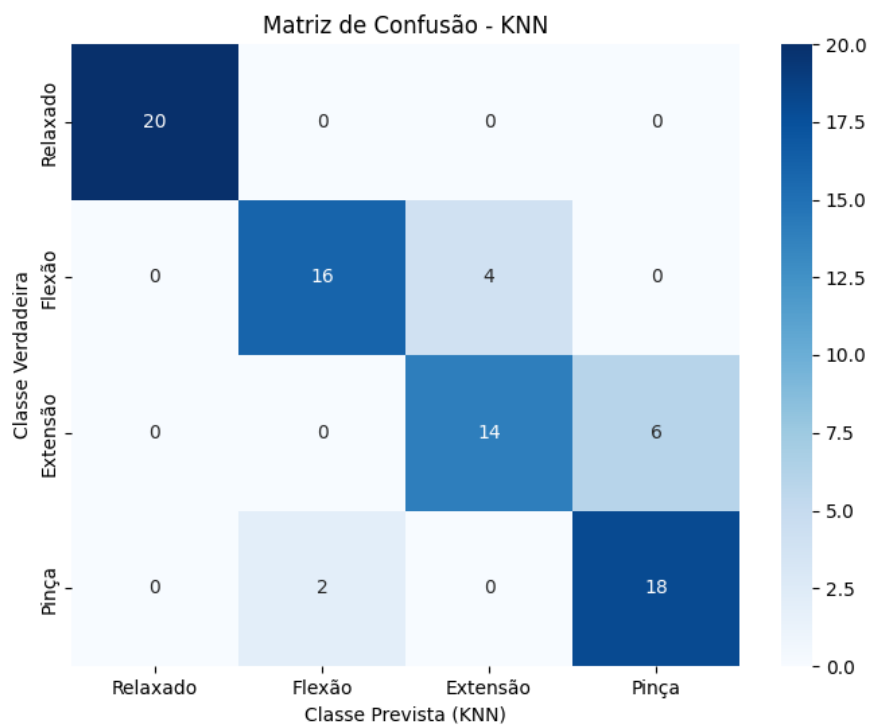
A análise da Figura 31 evidencia o desempenho do modelo KNN na classificação de amostras em diferentes classes. Observa-se que todas as 20 amostras pertencentes à classe "Relaxado" foram corretamente identificadas. Em relação à classe "Flexão", 16 amostras foram classificadas corretamente, enquanto 4 foram erroneamente classificadas como pertencentes à classe "Extensão". Quanto à classe "Extensão", 14 amostras foram classificadas corretamente, enquanto 5 foram incorretamente classificadas como "Pinça". Por fim, para a classe "Pinça", 18 amostras foram classificadas corretamente, havendo 2 amostras que foram erroneamente classificadas como "Flexão".

Em relação à Figura 32, destaca-se que todas as 20 amostras das classes "Relaxado" e "Pinça" foram corretamente identificadas. Para a classe "Flexão", 18 amostras foram classificadas corretamente, enquanto 2 foram erroneamente classificadas como pertencentes à classe "Pinça". Já para a classe "Extensão", 11 amostras foram corretamente classificadas, porém 9 amostras foram equivocadamente classificadas como pertencentes à classe "Relaxado".

A análise dos resultados revela que o modelo SVM demonstrou um desempenho superior na classificação das classes "Pinça" e "Flexão", ao passo que o modelo KNN obteve um desempenho superior na classificação da classe "Extensão". É válido ressaltar que ambos os modelos alcançaram a mesma taxa de acurácia na classificação da classe "Relaxado".


Durante a realização dos testes de processamento em tempo real, foram identificados tanto melhorias como problemas a serem abordados. Um dos problemas encontrados foi a suscetibilidade da placa de aquisição de sinais mioelétricos utilizada a ruídos. Dependendo do ambiente e da proximidade com outros dispositivos eletrônicos, o sinal capturado apresentava níveis significativos de ruído, o que afetava a precisão da classificação. Esforços adicionais devem ser direcionados para o aprimoramento do sistema de aquisição de sinais, visando uma maior imunidade a interferências externas.

Figura 31 – Matriz de Confusão - Tempo Real - KNN



Fonte: Produção do próprio autor.

Figura 32 – Matriz de Confusão - Tempo Real - SVM



Fonte: Produção do próprio autor.

		Acurácia	Precisão	Recall	F1-Score
KNN	Relaxado	85,00 %	100 %	100 %	84,93%
	Flexão		88,89%	80,00 %	
	Extensão		77,78 %	70,00%	
	Pinça		75,00 %	90,00%	
SVM	Relaxado	86,25 %	68,97%	100%	85,64%
	Flexão		100%	90,00%	
	Extensão		100%	55,00%	
	Pinça		90,91%	100%	

Tabela 7 – Métricas de Desempenho - Processamento em Tempo Real

Fonte: Produção do próprio autor.

Além disso, é importante ressaltar que a prótese em si ainda está em fase de desenvolvimento e otimização. Durante os testes, foi observado que alguns dedos apresentavam travamentos mecânicos e que, ocasionalmente, o servo não respondia corretamente ao comando recebido. Esses desafios mecânicos e de engenharia serão investigados para melhorar a confiabilidade e a funcionalidade da prótese.

No geral, os resultados obtidos até o momento são promissores e indicam o potencial desse sistema de baixo custo desenvolvido para a aplicação em próteses mioelétricas. No entanto, é importante destacar que ainda há espaço para aprimoramentos tanto no processamento dos sinais mioelétricos quanto na própria prótese, visando um sistema mais robusto e eficiente.

5 CONCLUSÃO E TRABALHOS FUTUROS

O objetivo principal deste trabalho foi o acionamento de uma prótese de mão, fabricada em impressora 3D e controlada por sinais mioelétricos. A abordagem proposta baseou-se na utilização de componentes acessíveis e algoritmos de aprendizado de máquina para a classificação multiclasse de 4 movimentos, com o intuito de proporcionar um acionamento mais eficiente e intuitivo para o usuário.

O presente estudo foi motivado pela ideia de tornar essa tecnologia acessível às pessoas que necessitam dela. Além disso, a proposta visou superar os desafios enfrentados pelas próteses passivas convencionais, como a falta de sensibilidade e a limitação nos movimentos.

Como resultado do desenvolvimento e aplicação da técnica proposta, foi possível alcançar uma taxa de acerto significativa na classificação em tempo real dos movimentos mioelétricos, obtendo uma média de acurácia de 85,00% para o algoritmo KNN e 86,25% para o algoritmo SVM.

Os sinais mioelétricos capturados foram processados e analisados, permitindo a extração de características para a classificação. A utilização de algoritmos de aprendizado de máquina, como o SVM e o KNN, demonstrou ser eficaz na diferenciação dos padrões de contração muscular e na identificação dos movimentos desejados. Entretanto, não foi possível encontrar uma resposta satisfatória com os algoritmos LDA e RF para este problema.

A partir dos valores obtidos nas métricas de avaliação do desempenho do sistema, como acurácia, precisão, *recall* e *F1-Score*, foi possível avaliar a robustez e a efetividade da técnica proposta. Os resultados obtidos demonstraram uma taxa de acerto consistente e um bom desempenho na identificação dos movimentos, conforme Tabela 7, indicando que a abordagem adotada é promissora para o controle de próteses mioelétricas.

Este trabalho contribui para o avanço da área de próteses mioelétricas, proporcionando uma solução de baixo custo para o controle desses dispositivos.

Além disso, este estudo também contribui para a área de processamento de sinais e aprendizado de máquina, já que as metodologias utilizadas e os resultados alcançados podem servir de base para futuras pesquisas e desenvolvimentos na área.

No entanto, é importante ressaltar que ainda existem desafios a serem superados, portanto, os trabalhos futuros pretendem buscar como aprimorar a proteção a ruídos e a confiabilidade do sistema de aquisição de sinais, bem como aperfeiçoar a mecânica e a resposta da prótese. Além disso, é necessário fazer modificações para que ela seja vestível e com a eletrônica embarcada, sem a necessidade de estar conectada a algum computador. O desenvolvimento contínuo dessas tecnologias é fundamental para garantir uma melhor experiência e funcionalidade para os usuários de próteses mioelétricas.

Por fim, espera-se que este trabalho possa contribuir para o avanço das pesquisas na área de próteses mioelétricas e abrir novas possibilidades para o desenvolvimento de dispositivos mais sofisticados e eficientes, capazes de auxiliar no dia a dia e na qualidade de vida das pessoas amputadas.

REFERÊNCIAS

- ADAFRUIT. Adafruit 16-Channel 12-bit PWM/Servo Driver - I2C interface - PCA9685. 2015. Disponível em: <<https://www.adafruit.com/product/815>>. Acesso em: 1 de jul. de 2023. Citado na página 38.
- ANDRADE, N. A. Desenvolvimento de um sistema de aquisição e processamento de sinais eletromiográficos de superfície para a utilização no controle de próteses motoras ativas. 2007. Citado na página 21.
- AQUINO, C. F. de. Eletromiografia: interpretação e aplicações nas ciências da reabilitação. Fisioterapia Brasil, v. 6, n. 4, p. 305–310, 2005. Citado na página 21.
- ARDUINO. UNO R3. 2010. Disponível em: <<https://docs.arduino.cc/hardware/uno-rev3>>. Acesso em: 1 de jul. de 2023. Citado na página 37.
- BASMAJIAN, J. V. Muscles alive. their functions revealed by electromyography. Academic Medicine, LWW, v. 37, n. 8, p. 802, 1962. Citado na página 21.
- BIEDERMANN, W.; WELBY, F. Electro-physiology. Macmillan, 1898. (Electro-physiology, v. 2). Disponível em: <<https://books.google.com.br/books?id=NgcFAAAAYAAJ>>. Citado na página 21.
- BOELTER, J. d. S. Classificação de sinais eletromiográficos utilizando redes neurais artificiais, análise discriminante linear e floresta aleatória. Universidade do Vale do Rio dos Sinos, 2021. Citado na página 27.
- BOIS-REYMOND, E. D. Untersuchungen über thierische elektricität: bd., 1. abth. [S.l.]: G. Reimer, 1849. v. 2. Citado na página 21.
- BOTH, J. E.; BADKE, M. R.; DAANDELS, N.; HEPP, D. R.; SANTOS, A. M. Acompanhamento de paciente com amputação de membro superior: um estudo de caso. Revista Contexto & Saúde, v. 11, n. 20, p. 611–616, 2011. Citado na página 12.
- BRASIL, M. d. S. Diretrizes de atenção à pessoa amputada. Brasília: Ministério da Saúde., v. 1, 2013. Citado na página 19.
- BRASIL, M. d. S. Informações de Saúde (TABNET). 2016. Disponível em: <<https://datasus.saude.gov.br/>>. Citado na página 19.
- BREIMAN, L. Random forests. Machine learning, Springer, v. 45, p. 5–32, 2001. Citado na página 27.
- BRONZINO, J. D.; PETERSON, D. R. Biomedical engineering fundamentals. [S.l.]: CRC press, 2014. v. 3. Citado na página 22.
- BUFFONE, B. Touch Bionics i-limb prosthesis is controlled by an iPhone app. 2013. Disponível em: <<https://www.cnet.com/tech/computing/touch-bionics-i-limb-prosthesis-is-controlled-by-an-iphone-app/>>. Acesso em: 21 de jul. de 2022. Citado 2 vezes nas páginas 12 e 20.

- BURMAN, P. A comparative study of ordinary cross-validation, v-fold cross-validation and the repeated learning-testing methods. Biometrika, Oxford University Press, v. 76, n. 3, p. 503–514, 1989. Citado na página 28.
- CAMARGO, L.; STOPPA, M. Controle sem fio por dispositivos móveis de prótese biônica de mão. 2015. Citado na página 12.
- CRUZ, G. G. F. d. et al. Classificação dos movimentos da mão baseados na aquisição não invasiva de sinais mioelétricos provenientes dos músculos do antebraço através de redes neurais artificiais. Florianópolis, SC, 2018. Citado 6 vezes nas páginas 12, 14, 15, 18, 19 e 20.
- CUNHA, F. L.; FRANCA, J. E.; ORTOLAN, R. L.; CLIQUET, A. J. O uso de redes neurais artificiais para o reconhecimento de padrões em uma prótese mioelétrica de mão. In: VIII Congresso Brasileiro de Redes Neurais. [S.l.: s.n.], 2007. Citado na página 30.
- CUNHA, J. P. Z. Um estudo comparativo das técnicas de validação cruzada aplicadas a modelos mistos. Tese (Doutorado) — Universidade de São Paulo, 2019. Citado 2 vezes nas páginas 28 e 50.
- ENGLEHART, K. Signal representation for classification of the transient myoelectric signal. Electrical and Computer Engineering Department, 1998. Citado na página 30.
- FABRIS, C. M. Modelagem e análise de tensão para prótese de mão. Dissertação (B.S. thesis) — Universidade Tecnológica Federal do Paraná, 2022. Citado na página 14.
- FERRERO, C. A. Algoritmo kNN para previsão de dados temporais: funções de previsão e critérios de seleção de vizinhos próximos aplicados a variáveis ambientais em limnologia. Tese (Doutorado) — Universidade de São Paulo, 2009. Citado na página 27.
- FISHER, R. A. The use of multiple measurements in taxonomic problems. Annals of eugenics, Wiley Online Library, v. 7, n. 2, p. 179–188, 1936. Citado na página 27.
- FUKUDA, O.; TSUJI, T.; OHTSUKA, A.; KANEKO, M. Emg-based human-robot interface for rehabilitation aid. In: IEEE. Proceedings. 1998 IEEE International Conference on Robotics and Automation (Cat. No. 98CH36146). [S.l.], 1998. v. 4, p. 3492–3497. Citado na página 30.
- GALVANI, L.; ALDINI, G. et al. De viribus electricitatis in motu musculari: commentarius cum Joannis Aldini dissertatione et notis: accesserunt epistolae ad animalis electricitatis theoriam pertinentes. [S.l.]: Soc. Typogr., 1792. Citado na página 21.
- GODOI, T. d. S. M. d. Prótese mioelétrica controlada por redes neurais. 2014. Citado 5 vezes nas páginas 21, 23, 24, 30 e 31.
- GRAUPE, D.; CLINE, W. K. Functional separation of emg signals via arma identification methods for prosthesis control purposes. IEEE Transactions on Systems, Man, and Cybernetics, IEEE, n. 2, p. 252–259, 1975. Citado na página 30.
- HALL, S. J. Biomecânica Básica. [S.l.]: Grupo Gen-Guanabara Koogan, 2000. Citado 3 vezes nas páginas 14, 16 e 17.

HUDGINS, B.; PARKER, P.; SCOTT, R. N. A new strategy for multifunction myoelectric control. IEEE transactions on biomedical engineering, IEEE, v. 40, n. 1, p. 82–94, 1993. Citado na página 30.

INMOOV. Hand and Forarm. 2014. Disponível em:<<https://inmoov.fr/hand-and-forarm/>>. Acesso em: 30 de jul. de 2022. Citado 2 vezes nas páginas 12 e 37.

JORGE, A. R. F. et al. Dados epidemiológicos nacionais de amputação e proposta de dispositivo para treinamento de usuários de próteses de membro superior. Universidade Federal de Uberlândia, 2020. Citado 2 vezes nas páginas 19 e 20.

JUNIOR, B. N. N. A eletromiografia associada à inteligência artificial no diagnóstico de doenças e no rendimento físico. Universidade Estadual Paulista (Unesp), 2021. Citado 4 vezes nas páginas 21, 22, 23 e 24.

JUNIOR, G. B. V.; LIMA, B. N.; PEREIRA, A. A.; RODRIGUES, M. F.; OLIVEIRA, J. R. L.; SILIO, L. F.; CARVALHO, A. S.; FERREIRA, H. R.; PASSOS, R. P. Métricas utilizadas para avaliar a eficiência de classificadores em algoritmos inteligentes. Revista CPAQV–Centro de Pesquisas Avançadas em Qualidade de Vida| Vol, v. 14, n. 2, p. 2, 2022. Citado 3 vezes nas páginas 28, 29 e 37.

KELLY, M. F.; PARKER, P. A.; SCOTT, R. N. Myoelectric signal analysis using neural networks. IEEE Engineering in Medicine and Biology Magazine, IEEE, v. 9, n. 1, p. 61–64, 1990. Citado na página 30.

KONRAD, P. The abc of emg. A Practical Introduction to Kinesiological Electromyography, v. 1.4, n. 2006, p. 5–61, 2006. Citado 3 vezes nas páginas 21, 22 e 23.

LATHI, B. P.; GREEN, R. A. Linear systems and signals. [S.l.]: Oxford University Press New York, 2005. v. 2. Citado na página 22.

LOPES, E. d. M. C. Development and optimization of a low-cost myoelectric upper limb prosthesis. Tese (Doutorado), 2022. Citado 6 vezes nas páginas 20, 22, 25, 26, 31 e 37.

MAYOR, J. J. V. Muscle-computer interface based on pattern recognition of myoelectric signals for control of dexterous hand and finger movements of prostheses for forearm amputees. 2017. Citado 6 vezes nas páginas 22, 23, 24, 25, 30 e 37.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. Sistemas inteligentes-Fundamentos e aplicações, v. 1, n. 1, p. 32, 2003. Citado 4 vezes nas páginas 26, 28, 29 e 49.

NISHIKAWA, D.; YU, W.; YOKOI, H.; KAKAZU, Y. Emg prosthetic hand controller discriminating ten motions using real-time learning method. In: IEEE. Proceedings 1999 IEEE/RSJ International Conference on Intelligent Robots and Systems. Human and Environment Friendly Robots with High Intelligence and Emotional Quotients (Cat. No. 99CH36289). [S.l.], 1999. v. 3, p. 1592–1597. Citado na página 30.

OSHIRO, T. M. Uma abordagem para a construção de uma única árvore a partir de uma Random Forest para classificação de bases de expressão gênica. Tese (Doutorado) — Universidade de São Paulo, 2013. Citado na página 27.

OSSUR. i-Limb Quantum. 2021. Disponível em:<<https://www.ossur.com/pt-br/proteses/bracos/i-limb-quantum#downloadsContentAnchor>>. Acesso em: 10 de jul. de 2023. Citado na página 20.

OTTOBOCK. Ottobock Bebionic Hand Flex. 2020. Disponível em:<<https://www.ottobock.com/pt-br/product/8E72>>. Acesso em: 10 de jul. de 2023. Citado na página 20.

PASSOS, L. F. C. Métodos de regularização no aprendizado de máquinas: Ridge e lasso. 2022. Citado 2 vezes nas páginas 29 e 30.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E. Scikit-learn: Machine learning in Python. Journal of Machine Learning Research, v. 12, p. 2825–2830, 2011. Citado 2 vezes nas páginas 29 e 51.

PEIXOTO, A. M.; ZIMPEL, S. A.; OLIVEIRA, A. C. A. d.; MONTEIRO, R. L. S.; CARNEIRO, T. K. G. Prevalência de amputações de membros superiores e inferiores no estado de alagoas atendidos pelo sus entre 2008 e 2015. Fisioterapia e Pesquisa, SciELO Brasil, v. 24, p. 378–384, 2017. Citado na página 19.

REITER, R. Grenzgebiete der medizin, 1948, ch. Eine neue elektrokunsthand, p. 133–135, 1948. Citado na página 30.

REMIGIO, M. Máquina de Vetores de Suporte SVM. 2020. Disponível em:<<https://medium.com/@msremigio/máquinas-de-vetores-de-suporte-svm-77bb114d02fc>>. Acesso em: 3 de jul. de 2023. Citado na página 51.

REZENDE, A. C. B.; FILHO, G. L.; VIEIRA, F. H. T. Aplicação da análise discriminante linear (lda) para classificação de sinais eletromiográficos (emg) de movimentos da mão. In: SBC. Anais da VII Escola Regional de Informática de Goiás. [S.l.], 2019. p. 351–360. Citado na página 27.

SEMOLINI, R. et al. Support vector machines, inferência transdutiva e o problema de classificação. Campinas, SP, 2002. Citado na página 27.

SHEEHAN, T. P. Rehabilitation and Prosthetic Restoration in Upper Limb Amputation. 2015. Disponível em:<<https://clinicalgate.com/rehabilitation-and-prosthetic-restoration-in-upper-limb-amputation/>>. Acesso em: 20 de jul. de 2022. Citado na página 19.

SILVA, A. C. d. et al. Análise discriminante linear em duas dimensões para classificação de dados químicos de segunda ordem. Universidade Federal da Paraíba, 2017. Citado na página 27.

SILVA, R. C. d. Eletromiografia de superfície: função neuromuscular e reprodutibilidade do método, uma revisão. 2010. Citado 2 vezes nas páginas 22 e 23.

SOBOTTA, J. Atlas de anatomia humana: cabeça, pescoço e extremidade superior. In: Atlas de anatomia humana: cabeça, pescoço e extremidade superior. [S.l.: s.n.], 2000. Citado 2 vezes nas páginas 14 e 15.

- SOUZA, J. O. d. O. d. Investigação de diferentes métodos e recursos para controle de prótese de mão através da classificação de sinais emg via aprendizado de máquina. Universidade do Vale do Rio dos Sinos, 2021. Citado 2 vezes nas páginas 26 e 36.
- SPIEWAK, C.; ISLAM, M.; ZAMAN, A.; RAHMAN, M. H. et al. A comprehensive study on emg feature extraction and classifiers. Open Access Journal of Biomedical Engineering and Biosciences, v. 1, n. 1, p. 1–10, 2018. Citado 2 vezes nas páginas 25 e 26.
- ST. STM32F401RE. 2015. Disponível em:<<https://www.st.com/en/microcontrollers-microprocessors/stm32f401re.html>>. Acesso em: 3 de jul. de 2023. Citado na página 33.
- SYMBIOS. 2023. Disponível em:<<https://www.linkedin.com/company/symbiosbr/>>. Acesso em: 10 de jul. de 2023. Citado 3 vezes nas páginas 12, 33 e 41.
- TI. LM2596. 1999. Disponível em:<<https://www.ti.com/lit/ds/symlink/lm2596.pdf>>. Acesso em: 3 de jul. de 2023. Citado na página 38.
- TI. ADS1293. 2014. Disponível em:<<https://www.ti.com/lit/gpn/ADS1293>>. Acesso em: 3 de jul. de 2023. Citado 2 vezes nas páginas 33 e 41.
- TOMÉ, F. B. Metodologias de concepção de eletrodos para eletromiografia de superfície. 2015. Citado 2 vezes nas páginas 23 e 24.
- VASCONCELOS, B. F. B. d. Poder preditivo de métodos de machine learning com processos de seleção de variáveis: uma aplicação às projeções de produto de países. 2017. Citado 2 vezes nas páginas 29 e 30.
- VELEDA, W. S. J. Panorama do machine learning em farmácia clínica. 2019. Citado na página 27.
- VELLOSO, R. P. Protótipo de um eletromiógrafo digital. Trabalho de Conclusão de Curso, IFURBFG, Blumenal-SC, 2004. Citado na página 25.
- VIANA, P. Identificação de movimentos da mão por machine learning utilizando eletromiografia de superfície. Escola de Engenharia de São Carlos, USP, 2019. Citado na página 22.
- WILLIAMS, W. Ottobock bebionic Hand. 2022. Disponível em:<<https://bionicsforeveryone.com/ottobock-bebionic-hand/>>. Acesso em: 21 de jul. de 2022. Citado na página 20.
- ZECCA, M.; MICERA, S.; CARROZZA, M. C.; DARIO, P. Control of multifunctional prosthetic hands by processing the electromyographic signal. Critical Reviews™ in Biomedical Engineering, Begel House Inc., v. 30, n. 4-6, 2002. Citado 2 vezes nas páginas 30 e 31.
- ZHANG, Z.; YANG, K.; QIAN, J.; ZHANG, L. Real-time surface emg pattern recognition for hand gestures based on an artificial neural network. Sensors, MDPI, v. 19, n. 14, p. 3170, 2019. Citado na página 25.
- ZHOU, H.; ALICI, G. A compact and cost-effective pattern recognition based myoelectric control system for robotic prosthetic hands. In: IEEE. 2020 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM). [S.l.], 2020. p. 270–275. Citado 2 vezes nas páginas 30 e 37.