



Programa de Pós-Graduação em  
**Computação Aplicada**  
Doutorado Acadêmico

João Olegário de Oliveira de Souza

Investigação de Diferentes Métodos e Recursos para o Controle de  
Prótese de Mão Através da Classificação de Sinais EMG via  
Aprendizado de Máquina

São Leopoldo, 2021



JOÃO OLEGÁRIO DE OLIVEIRA DE SOUZA

**INVESTIGAÇÃO DE DIFERENTES MÉTODOS E RECURSOS PARA CONTROLE  
DE PRÓTESE DE MÃO ATRAVÉS DA CLASSIFICAÇÃO DE SINAIS EMG VIA  
APRENDIZADO DE MÁQUINA**

Tese apresentada como requisito parcial  
para obtenção do título de Doutor em  
Computação Aplicada, pelo Programa de  
Pós-Graduação em Computação Aplicada  
da Universidade do Vale do Rio dos Sinos  
- UNISINOS

Orientador: Prof. Dr. Sandro José Rigo

Coorientador: Prof. Dr. Rodrigo Marques de Figueiredo

São Leopoldo

2021

S729i Souza, João Olegário de Oliveira de  
Investigação de diferentes métodos e recursos para o controle de prótese de mão através da classificação de sinais EMG via aprendizado de máquina / por João Olegário de Oliveira de Souza. – 2021.  
184 f. : il., 30 cm.

Tese (doutorado) — Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, 2021.

Orientação: Prof. Dr. Sandro José Rigo ; Coorientação: Prof. Dr. Rodrigo Marques de Figueiredo.

1. Aprendizado de máquina. 2. Prótese de mão.  
3. Eletromiografia. 4. Inteligência artificial. 5. Reconhecimento de padrões. I. Título.

CDU 004.89

Catálogo na Fonte:

Biblioteca Vanessa Borges Nunes - CRB 10/1556

*À minha família, fonte de amor e apoio incondicional.*

## **AGRADECIMENTOS**

*Em especial, agradeço aos meus pais queridos, Euclides (in memorian) e Eloeci, pela vida, todo o esforço e amor inesgotável.*

*Ao professor orientador Dr. Sandro José Rigo e ao professor coorientador Dr. Rodrigo Marques de Figueiredo pelas orientações valiosas e todo o apoio, fundamentais para a execução desta tese.*

*E com muito amor, agradeço a minha esposa e companheira Aline e aos meus filhos, Heitor e Vicente, que tiveram que suportar minha ausência em muitos momentos, para que este trabalho pudesse ser realizado.*

*A Deus por me proporcionar perseverança e força durante toda minha vida.*

*“Feliz aquele que transfere o que sabe  
e aprende o que ensina”.*

*(Cora Coralina)*

## RESUMO

Os avanços tecnológicos dos últimos anos permitiram o desenvolvimento de próteses de mão que possuem maior precisão nos movimentos, redução do peso e o uso de sinais bioelétricos em sua operação. Hoje as próteses com controle mioelétrico são consideradas o estado da arte neste segmento, representando uma grande ferramenta na restauração de parte das tarefas habituais e na melhoria da qualidade de vida dos amputados de membros superiores. Contudo, o controle destes equipamentos não é intuitivo pois os usuários das próteses necessitam realizar sequencias complexas de impulsos de contração muscular para alterar o tipo de movimento a executar. O objetivo desta tese foi o desenvolvimento de um sistema em tempo real para controle de mãos protéticas mioelétricas utilizando Aprendizado de Máquina. A arquitetura do sistema incluiu a integração dos dispositivos de aquisição de sinais eletromiográficos (EMG), plataforma para implementação do classificador em tempo real e *interface* para acionamento elétrico de servomotores para uma prótese de mão *open source*. Os seguintes modelos de classificadores foram implementados e comparados: uma Rede Neural Multicamadas, uma Rede Neural Convolutacional, Rede Neural Recorrente utilizando unidades LSTM e uma Floresta Aleatória. Os ensaios foram realizados primeiramente em sistemas *offline* envolvendo o processamento de três bancos de dados, incorporando e avaliando de forma incremental diferentes recursos e sensores até a implementação do sistema *online*. Um classificador Multilayer Perceptron (MLP) foi implementado em uma plataforma para prototipagem rápida (Raspberry Pi 3 modelo B+) obtendo taxas médias de acerto de 96,3% (*offline*) e 87,2% (*online*) e respostas em tempo real (10,3 ms) para 11 gestos de mão.

**Palavras-chave:** Aprendizado de máquina, Prótese de mão, Eletromiografia, Inteligência Artificial, Reconhecimento de padrões.



## ABSTRACT

The technological advances in the last years have allowed the development of hand prostheses that have more movement precision, weight reduction and the use of bioelectric signals in its operation. Nowadays, the prostheses with myoelectric control are considered the state of art in this segment; they represent a great tool in the restoration of parts of daily tasks and in the improvement of life quality for upper limb amputees. However, the control of these devices is not intuitive, because the users of myoelectric prostheses need to perform complex sequences of muscle contraction impulses to change the type of movement. The goal of this thesis was the development of a real-time myoelectric control of a hand prosthesis using Machine Learning. The system architecture includes the integration of the electromyographic (EMG) signal acquisition devices, platform for the implementation of the real-time classifier and interface for servomotor driver for an open source hand prosthesis. The following classifier models were implemented and compared: Multilayer Neural Network, Convolutional Neural Network, Recurrent Neural Network using LSTM units and Random Forest. Firstly, the assays were performed on offline systems involving the three databases processing, incrementally incorporating and evaluating different resources and sensors until the implementation of the online system. A Multilayer Perceptron (MLP) classifier was implemented on a platform for rapid prototyping (Raspberry Pi 3 model B+) obtaining average accuracies of 96.3% (offline) and 87.2% (online) and responses in real-time (10.3 ms) for 11 hand gestures.

**Keywords:** Machine Learning, Hand Prosthesis, Electromyography, Artificial Intelligence, Pattern Recognition.

## LISTA DE FIGURAS

Figura 1 - Utilização de prótese para realização de AVD .....	20
Figura 2 - Ossos do punho e mão .....	28
Figura 3 - Estrutura de um músculo esquelético .....	29
Figura 4 - Tipos de preensões digitais, palmares e centrais .....	30
Figura 5 - Níveis de amputação do membro superior .....	32
Figura 6 - Próteses passivas e ativas.....	33
Figura 7 - Prótese de mão comerciais.....	34
Figura 8 - Prótese de mão <i>open source</i> .....	36
Figura 9 - Representação dos elementos básicos do controle motor.....	38
Figura 10 - Esquema de formação de uma MUAP .....	39
Figura 11 - Eletrodos ativos com amplificador diferencial .....	41
Figura 12 - Posicionamentos dos eletrodos superficiais no braço.....	41
Figura 13 - Movimentos realizados no NinaPro DB2.....	44
Figura 14 - Abordagem clássica para reconhecimento de padrões EMG .....	45
Figura 15 - Abordagem para reconhecimento de padrões EMG baseada em aprendizagem profunda.....	45
Figura 16 - Exemplo de segmentação de um sinal EMG .....	46
Figura 17 - Modelo de um neurônio artificial .....	49
Figura 18 - Arquitetura <i>Feedforward</i> com múltiplas camadas .....	53
Figura 19 - Arquitetura de uma rede neural recorrente .....	55
Figura 20 - Esquemático de uma rede LSTM.....	56
Figura 21 - Arquitetura de uma rede neural convolucional.....	57
Figura 22 - Operação de convolução para uma entrada 2D .....	58
Figura 23 - Função <i>max-pooling</i> .....	59
Figura 24 - Técnica <i>Dropout</i> .....	60
Figura 25 - Esquema do processo de classificação de uma Floresta Aleatória .....	61
Figura 26 - Diagrama de blocos das etapas para implementação .....	72
Figura 27 - Diagrama de blocos do modelo <i>Offline</i> de reconhecimento de padrões .....	74
Figura 28 - Plataforma BITalino, modelo MuscleBIT .....	80

Figura 29 - Foto do arranjo experimental utilizado para a aquisição de sinais EMG: (1) computador para a visualização dos gestos/movimentos de mão; (2a e 2b) arranjo de dois módulos de aquisição de sinais EMG; (3) dezesseis eletrodos de superfície para os oito canais EMG e dois eletrodos (de superfície) para referência; (4) condicionadores de sinais; (5a e 5b) conjunto de cabos para conexão dos condicionadores de sinais aos módulos de aquisição; (6a e 6b) cabos para conexão dos eletrodos de referência aos módulos de aquisição; (7) cabo de sincronização dos módulos de aquisição; (8) computador com programa para a aquisição e registros dos sinais EMG.....	81
Figura 30 - Posicionamento e fixação dos eletrodos no braço de cada voluntário....	83
Figura 31 - Fluxograma para procedimento de aquisição e gravação dos sinais EMG .....	84
Figura 32 - Imagem do ensaio realizado .....	86
Figura 33 - Aquisição de sinais EMG com os oito canais do sistema BITalino .....	86
Figura 34 - Marcação de início e término da atividade muscular .....	89
Figura 35 - Marcação de início e término da atividade muscular .....	89
Figura 36 - Trecho do <i>dataset</i> KidoPro (voluntário 1).....	90
Figura 37 - a) Sinal EMG não processado; b) Sinal EMG retificado; c) Sinal EMG normalizado (banco de dados KidoPro, sujeito 4, canal 2, classe 4).....	92
Figura 38 - Entrada de dados dos classificadores.....	94
Figura 39 - Diagrama de blocos do sistema <i>Online</i> .....	97
Figura 40 - Plataforma de prototipação Raspberry Pi 3 B+ .....	99
Figura 41 - Prótese de mão <i>Hand Robot inMoov</i> .....	101
Figura 42 - Experimento para prensão e deslocamento de objeto .....	104
Figura 43 - (a) Aquisição de sinais de 4 canais EMG; (b) Aquisição de sinais de 4 canais ACC; (c) Classificação dos movimentos de mão utilizando apenas sinais EMG; (d) Classificação combinando eletromiografia com acelerometria. Nota: banco de dados DB3, classificador RF, voluntário 3, classificador RF. ....	122
Figura 44 - Matrizes de confusão do classificador MLP: .....	131
Figura 45 - Matrizes de confusão do classificador RF:.....	132
Figura 46 - Classificação <i>real-time</i> dos movimentos/gestos de mão do voluntário 2 ...	138
Figura 47 - Classificação <i>real-time</i> dos movimentos/gestos de mão do voluntário 3 ...	139

Figura 48 - Classificação <i>real-time</i> dos movimentos/gestos de mão do voluntário 4 ...	139
Figura 49 - Exemplos de movimentos/gestos de mão realizados com a prótese....	140
Figura 50 - Experimento de apreensão e deslocamento de objetos .....	141
Figura 51 - Execução de gestos através do reconhecimento de voz .....	145
Figura 52 - Dispositivo para aquisição de sinais EMG: (a) bracelete com eletrodos, condicionador de sinais, sistema embarcado e bateria; (b) posicionamento do bracelete para experimentos; (c) interface gráfica com os sinais EMG adquiridos .....	145
Figura 53 - Dispositivo para aquisição de sinais EEG: (a) placa de circuito impresso do condicionador de sinais; (b) posicionamento dos eletrodos EEG ....	146
Figura 54 - Diagrama de blocos apresentando as oportunidades de trabalhos futuros a partir desta tese .....	147
Figura 55 - Sistema mecânico da prótese de mão .....	151
Figura 56 - Diagrama de blocos do acionamento elétrico .....	151
Figura 57 - Leitura de velocidade e sentido de rotação de motor.....	152
Figura 58 - <i>Driver</i> para acionamento dos motores de corrente contínua .....	153
Figura 59 - Plataformas de aquisição de sinais EMG.....	173
Figura 60 - Plataformas de prototipagem .....	174
Figura 61 - Matriz de confusão do classificador MLP para 50 classes ( <i>dataset</i> DB2) .....	177
Figura 62 - Matriz de confusão do classificador RF para 50 classes ( <i>dataset</i> DB2)	178
Figura 63 - Matriz de confusão do classificador MLP para 50 classes ( <i>dataset</i> DB3) .....	179
Figura 64 - Matriz de confusão do classificador RF para 50 classes ( <i>dataset</i> DB3)	180

## LISTA DE GRÁFICOS

Gráfico 1 - Função limiar .....	51
Gráfico 2 - Função sigmóide .....	51
Gráfico 3 - Função ReLu .....	52
Gráfico 4 - Acurácia dos classificadores considerando 12 classes e quatro classificadores: .....	109
Gráfico 5 - Acurácia dos classificadores considerando 12 classes e quatro classificadores: .....	109
Gráfico 6 - Acurácia dos classificadores considerando 50 classes da base de dados DB2:.....	111
Gráfico 7 - Acurácia dos classificadores considerando 50 classes da base de dados DB3:.....	112
Gráfico 8 - Histograma da acurácia de classificação sobre movimentos (classificador RF): (a) banco de dados DB2; (b) banco de dados DB3. ....	114
Gráfico 9 - Histograma da acurácia de classificação sobre movimentos (classificador MLP): (a) banco de dados DB2; (b) banco de dados DB3.....	114
Gráfico 10 - Acurácia dos classificadores para diferentes configurações de segmentação na base de dados DB2: (a) acurácias (média) de cada voluntário utilizando o classificador MLP; (b) acurácia média do classificador MLP considerando os dez voluntários; (c) acurácias (média) de cada voluntário aplicando o classificador RF; (d) acurácia média do classificador RF considerando os dez voluntários. ....	115
Gráfico 11 - Acurácia dos classificadores para diferentes configurações de segmentação na base de dados DB3: (a) acurácias (média) de cada voluntário utilizando o classificador MLP; (b) acurácia média do classificador MLP considerando os dez voluntários; (c) acurácias (média) de cada voluntário aplicando o classificador RF; (d) acurácia média do classificador RF considerando os dez voluntários. ....	116
Gráfico 12 - Resultado da classificação para cinco conjuntos de eletrodos.....	118
Gráfico 13 - Resultado da classificação para cinco conjuntos de eletrodos.....	120

Gráfico 14 - Combinando eletromiografia com acelerometria (banco de dados DB2): (a) acurácia média de cada sujeito para o classificador MLP; (b) acurácia média para o classificador MLP; (c) acurácia média de cada sujeito para o classificador RF; (d) acurácia média para o classificador RF. ....	123
Gráfico 15 - Combinando eletromiografia com acelerometria (banco de dados DB3): (a) acurácia média de cada sujeito para o classificador MLP; (b) acurácia média para o classificador MLP; (c) acurácia média de cada sujeito para o classificador RF; (d) acurácia média para o classificador RF. ....	124
Gráfico 16 - Resultados dos diferentes métodos de redução da dimensionalidade em conjunto com os classificadores MLP e RF (banco de dados DB3). ....	127
Gráfico 17 - Acurácia dos classificadores para diferentes configurações de segmentação na base de dados KidoPro: (a) acurácias (média) ponderada e geral de cada voluntário utilizando o classificador MLP; (b) acurácia (média) ponderada do classificador MLP considerando os cinco voluntários; (c) acurácia (média) geral do classificador MLP considerando os cinco voluntários. ....	129
Gráfico 18 - Acurácia dos classificadores para diferentes configurações de segmentação na base de dados KidoPro: (a) acurácias (média) ponderada e geral de cada voluntário utilizando o classificador RF; (b) acurácia (média) ponderada do classificador RF considerando os cinco voluntários; (c) acurácia (média) geral do classificador RF considerando os cinco voluntários. ....	130
Gráfico 19 - Erro de classificação do classificador MLP para configurações intra-voluntários e inter-voluntários na base de dados KidoPro: (a) erros de classificação (média) de cada voluntário utilizando o classificador MLP; (b) erros de classificação (média) do classificador MLP considerando os cinco voluntários. ....	134
Gráfico 20 - Tempo de processamento das etapas de reconhecimento de gestos de mão do sistema <i>Online</i> . ....	136

## LISTA DE QUADROS

Quadro 1 - Variáveis do banco de dados NinaPro .....	42
Quadro 2 - Experimentos realizados .....	75
Quadro 3 - Pseudocódigo para criação do banco de dados de sinais EMG e classificação <i>offline</i> .....	78
Quadro 4 - Movimentos usados para o banco de dados KidoPro .....	85
Quadro 5 - Formatação do banco de dados KidoPro .....	90
Quadro 6 - <i>Features</i> extraídas dos sinais EMG utilizadas nesta tese .....	93
Quadro 7 - Especificações da plataforma Raspberry Pi 3 B+ .....	99
Quadro 8 - Etapas pseudocódigo do sistema de classificação <i>online</i> .....	100
Quadro 9 - Especificações dos motores de corrente contínua .....	152

## LISTA DE TABELAS

Tabela 1 - Características dos <i>datasets</i> NinaPro .....	43
Tabela 2 - Comparação de pesquisas de controle de próteses .....	66
Tabela 3 - Ensaio para diferentes conjuntos de canais EMG .....	76
Tabela 4 - Informações dos voluntários do banco de dados local.....	82
Tabela 5 - Posição angular de cada motor para cada gesto executado.....	103
Tabela 6 - Matriz de confusão de um classificador .....	105
Tabela 7 - Acurácia média e desvio-padrão dos classificadores implementados....	110
Tabela 8 - Acurácias médias para diferentes trabalhos, <i>dataset</i> DB2 e DB3.....	113
Tabela 9 - Contribuição de cada conjunto de canal - <i>Dataset</i> DB2 .....	119
Tabela 10 - Contribuição de cada conjunto de canal - <i>Dataset</i> DB3 .....	121
Tabela 11 - Acurácia média para diferentes trabalhos combinando sensores EMG e ACC e voluntários não amputados .....	125
Tabela 12 - Acurácia média dos trabalhos com bancos de dados próprios .....	133
Tabela 13 - Tempo de processamento das <i>features</i> .....	136
Tabela 14 - Execuções do experimento de prensão e deslocamento de objetos..	142
Tabela 15 - Comparação entre as plataformas de aquisição de biosinais .....	172
Tabela 16 - Comparação entre as plataformas de prototipação.....	173



## LISTA DE SIGLAS

ACC	<i>Accelerometry</i> (Acelerometria)
Adam	<i>Adaptive Moment Estimation</i>
AE	<i>Autoencoders</i>
ANFIS	<i>Adaptative Neural Fuzzy Inference System</i> (Sistema de Inferência Fuzzy baseado em Redes Adaptativas)
AMRIGS	Associação Médica do Rio Grande do Sul
AR	<i>Auto-Regressive</i> (Coeficientes de auto-regressão)
AVD	Atividades da Vida Diária
AVT	<i>Antonyan Vardan Transform</i> (Transformada de Antonyan Vardan)
CAAE	Certificado de Apresentação de Apreciação Ética
CART	<i>Classification and Regression Trees</i> (Árvores de classificação e regressão)
CMRR	<i>Common Mode Rejection Ratio</i> (Relação de Rejeição em Modo Comum)
CNN	<i>Convolutional Neural Network</i> (Redes Neurais Convolucionais)
CoS	<i>Cosine Similarity</i> (Cálculo de Similaridade)
DBN	<i>Deep Belief Network</i> (Redes de Crenças Profundas)
DL	<i>Deep Learning</i> (Aprendizagem Profunda)
DOF	<i>Degress of freedom</i> (graus de liberdade)
DPU	Defensoria Pública da União
DT	<i>Decision Tree</i> (Árvore de Decisão)
DTW	<i>Dynamic Time Warping</i> (Distorção dinâmica do tempo)
EAM	<i>Extended Associated Memories</i>
ECG	<i>Electrocardiography</i> (Eletrocardiografia)
EDA	<i>Electrodermal Activity</i> (Atividade Eletrodermal)
EEG	Eletroencefalografia
ELM	<i>Extreme Learning Machines</i>
EMG	Eletromiografia
FC	<i>Fully Connected</i> (totalmente conectada)
FD	<i>Frequency Domain</i> (Domínio da frequência)
FN	<i>False Negative</i> (Falso Negativo)
FP	<i>False Positive</i> (Falso Positivo)

GD	<i>Gradient Descent</i> (Gradiente Descendente)
GIR	Giroscópio
GPIO	<i>General Purpose Input Output</i> (Entrada/saída de propósito geral)
I <sup>2</sup> C	<i>Inter-Integrated-Circuit</i>
IDE	<i>Integrated Development Environment</i> (Ambiente de Desenvolvimento Integrado)
IMC	Índice de Massa Corporal
<i>json</i>	<i>JavaScript Object Notation</i>
KNN	<i>k Nearest Neighbor</i> (k-vizinhos mais próximos)
KRLS	<i>Kernel Recursive Least Squares</i> (Método Adaptativo baseado em <i>Kernels</i> )
LDA	<i>Linear Discriminant Analysis</i> (Análise de Discriminantes Lineares)
LIBRAS	Língua Brasileira de Sinais
LMT	<i>Logistic Model Tree</i>
LSTM	<i>Long-Short-Term-Memory</i>
LUX	<i>Light Sensor</i> (Sensor de luminosidade)
MAE	<i>Mean Absolute Error</i> (Erro Absoluto Médio)
MAG	Magnetômetro
MAT	Arquivo no formato do Matlab®
MAV	<i>Mean Absolute Value</i> (Média do Valor Absoluto)
ML	<i>Machine Learning</i> (Aprendizagem de máquina)
MLE	<i>Maximum Likelihood Estimation</i> (Estimativa da Máxima Verossimilhança)
MLP	<i>Multilayer Perceptron</i> ( <i>Perceptron</i> Multicamadas)
MNF	<i>Mean Frequency</i> (Frequência Média)
MSE	<i>Mean Squared Error</i> (Erro Quadrático Médio)
MU	<i>Motor Unit</i> (Unidade Motora)
MUAP	<i>Motor Unit Action Potential</i> (Potencial de ação da unidade motora)
NINAPRO	<i>Non-Invasive Adaptive Hand Prosthetics</i>
PD	Controlador Proporcional e Derivativo
PI	Controlador Proporcional e Integral
PID	Controlador Proporcional, Integral e Derivativo
PLGA	Ácido poli(lático-co-glicólico)
PLLA	Ácido polilático

PR	<i>Pattern Recognition</i> (Reconhecimento de padrões)
PVDF	Polifluoreto de vinilideno
QDA	<i>Quadratic Discriminant Analysis</i> (Análise Discriminante Quadrática)
RF	<i>Random Forest</i> (Floresta Aleatória)
RMS	<i>Root Mean Square</i> (Raiz Quadrática Média)
RMSE	<i>Root Mean Squared Error</i>
RNA	Rede Neural Artificial
RNN	<i>Recurrent Neural Network</i> (Redes Neurais Recorrentes)
RPM	Rotações por minuto
sEMG	Eletroniografia de Superfície
SENIAM	<i>Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles</i> (Eletroniografia de superfície para a avaliação não invasiva)
SGD	<i>Stochastic Gradient Descent</i> ( <i>Gradiente Descendente Estocástico</i> )
SIH/SUS	Sistema de Informações Hospitalares do Sistema Único de Saúde
SLR	<i>Simple Logistic Regression</i> (Regressão Logística)
SoC	<i>System On Chip</i> (Sistema em um <i>chip</i> )
SPI	<i>Serial Peripheral Interface</i>
STL	<i>Standard Tessellation Language</i>
SUS	Sistema Único de Saúde
SVM	<i>Support Vector Machine</i> (Máquinas de Vetores de Suporte)
TA	Tecnologia Assistiva
TCC	Trabalho de Conclusão de Curso
TCP	<i>Transmission Control Protocol</i> (Protocolo de Controle de Transmissão)
TD	<i>Time Domain</i> (Domínio do tempo)
TFD	<i>Time-Frequency Domain</i> (Domínio de tempo-frequência)
TN	<i>True Negative</i> (Negativo Verdadeiro)
TP	<i>True Positive</i> (Positivo Verdadeiro)
UART	<i>Universal Asynchronous Receiver/Transmitter</i>
UMI	Unidade de Medição Inercial
USB	<i>Universal Serial Bus</i> (Barramento Serial Universal)
WL	<i>Wave Length</i> (Comprimento da forma de onda)
WPT	<i>Wavelet Packet Transform</i> (Transformada <i>Wavelet Packet</i> )
ZC	<i>Zero Crossing</i> (Cruzamentos por Zero)

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>20</b>
1.1 QUESTÃO DE PESQUISA.....	22
1.2 OBJETIVOS .....	23
<b>1.2.1 Objetivo geral</b> .....	<b>23</b>
<b>1.2.2 Objetivos específicos</b> .....	<b>23</b>
1.3 DELIMITAÇÕES DO TRABALHO .....	24
1.4 JUSTIFICATIVAS.....	24
1.5 METODOLOGIA.....	25
1.6 ORGANIZAÇÃO DO TEXTO.....	25
<b>2 FISIOLOGIA HUMANA, PRÓTESES DE MÃO E ELETROMIOGRAFIA</b> .....	<b>27</b>
2.1 CONSIDERAÇÕES SOBRE A MÃO HUMANA .....	27
<b>2.1.1 Aspectos anatômicos</b> .....	<b>27</b>
<b>2.1.2 Fisiologia do músculo esquelético</b> .....	<b>28</b>
<b>2.1.3 Movimentos funcionais da mão</b> .....	<b>29</b>
<b>2.1.4 Amputação</b> .....	<b>32</b>
2.2 PRÓTESES PARA MEMBRO SUPERIOR .....	33
<b>2.2.1 Próteses comerciais</b> .....	<b>34</b>
<b>2.2.2 Próteses de baixo custo <i>open source</i></b> .....	<b>36</b>
2.3 ELETROMIOGRAFIA.....	37
<b>2.3.1 Unidade motora</b> .....	<b>37</b>
<b>2.3.2 Sinais EMG e sua detecção</b> .....	<b>39</b>
<b>2.3.3 Banco de dados NinaPro</b> .....	<b>41</b>
<b>2.3.4 Classificação de sinais EMG</b> .....	<b>45</b>
<b>3 APRENDIZADO DE MÁQUINA</b> .....	<b>48</b>
3.1 REDES NEURAIS ARTIFICIAIS .....	49
<b>3.1.1 Modelo de um neurônio</b> .....	<b>49</b>
<b>3.1.2 Função de Ativação</b> .....	<b>50</b>
<b>3.1.3 Camada <i>Softmax</i></b> .....	<b>52</b>
<b>3.1.4 Redes de camadas múltiplas</b> .....	<b>53</b>
<b>3.1.5 Redes Neurais Recorrentes</b> .....	<b>55</b>
<b>3.1.6 Redes Neurais Convolucionais</b> .....	<b>57</b>
<b>3.1.7 Floresta Aleatória</b> .....	<b>60</b>

3.2 REDUÇÃO DE DIMENSIONALIDADE .....	62
<b>4 TRABALHOS RELACIONADOS .....</b>	<b>64</b>
<b>5 MATERIAIS E MÉTODOS .....</b>	<b>72</b>
5.1 SISTEMA <i>OFFLINE</i> .....	73
5.1.1 Experimentos com bancos de dados NinaPro .....	75
5.1.2 Desenvolvimento do banco de dados local .....	77
5.1.3 Pré-processamento .....	91
5.1.4 Segmentação por janelas deslizantes .....	92
5.1.5 Extrator de características ( <i>features</i> ) .....	93
5.1.6 Entrada dos classificadores .....	94
5.1.7 Conjuntos de treinamento e de teste .....	95
5.1.8 Classificadores e otimização dos parâmetros .....	95
5.2 SISTEMA <i>ONLINE</i> .....	97
5.2.1 Plataforma de prototipação rápida .....	98
5.2.2 Elementos de <i>software</i> do sistema <i>Online</i> .....	100
5.2.3 Sistema Mecânico .....	101
5.2.4 Experimentos no sistema <i>Online</i> .....	102
5.3 AVALIAÇÃO DOS SISTEMAS DE RECONHECIMENTO DE GESTOS .....	105
5.3.1 Matriz de confusão .....	105
5.3.2 Métricas de avaliação de classificação .....	106
5.3.3 Tempo de processamento do sistema <i>Online</i> .....	107
5.3.4 Execução de tarefas no sistema <i>Online</i> .....	107
<b>6 RESULTADOS E DISCUSSÃO .....</b>	<b>108</b>
6.1 BANCOS DE DADOS NINAPRO .....	108
6.1.1 Classificadores .....	108
6.1.2 Efeito da Segmentação .....	115
6.1.3 Número de canais EMG .....	117
6.1.4 Combinando eletromiografia com acelerometria .....	121
6.1.5 Redução da dimensionalidade .....	127
6.2 BANCO DE DADOS KIDOPRO .....	128
6.2.1 Segmentação do banco de dados KidoPro .....	129
6.2.2 Comparação com a literatura existente .....	132
6.2.3 Classificação inter-voluntários .....	134
6.2.3 Sistema <i>Online</i> .....	135

<b>7 CONCLUSÕES E CONSIDERAÇÕES FINAIS .....</b>	<b>143</b>
7.1 CONTRIBUIÇÕES ACADÊMICAS.....	144
7.2 CONTINUIDADE E SUGESTÕES DE TRABALHOS FUTUROS.....	147
<b>7.2.1 Instrumentação eletroeletrônica .....</b>	<b>148</b>
<b>7.2.2 Expansão do banco de dados de voluntários locais .....</b>	<b>148</b>
<b>7.2.3 Pré-processamento e classificação de sinais EMG .....</b>	<b>149</b>
<b>7.2.4 Prótese de mão.....</b>	<b>150</b>
<b>REFERÊNCIAS.....</b>	<b>154</b>
<b>APÊNDICE A - PLATAFORMAS PARA AQUISIÇÃO DE SINAIS EMG .....</b>	<b>172</b>
<b>APÊNDICE B - PLATAFORMAS DE PROTOTIPAGEM RÁPIDA .....</b>	<b>173</b>
<b>APÊNDICE C - TERMO DE CONSENTIMENTO LIVRE ESCLARECIDO .....</b>	<b>174</b>
<b>APÊNDICE D - ANAMNESE.....</b>	<b>176</b>
<b>APÊNDICE E - MATRIZES DE CONFUSÃO (NINAPRO).....</b>	<b>177</b>
<b>APÊNDICE F - CUSTO DO PROTÓTIPO.....</b>	<b>182</b>
<b>APÊNDICE G - ARTIGO SOBRE PROJETO DE HARDWARE E SOFTWARE DE SISTEMA PARA CONTROLE DE PRÓTESE DE MÃO .....</b>	<b>183</b>
<b>APÊNDICE H - ARTIGO SOBRE INVESTIGAÇÃO DE MÉTODOS E RECURSOS PARA CONTROLE DE PRÓTESES DE MÃO UTILIZANDO APRENDIZADO DE MÁQUINA NA CLASSIFICAÇÃO DE SINAIS EMG.....</b>	<b>184</b>

## 1 INTRODUÇÃO

Segundo dados da Organização Mundial da Saúde (OMS), 75% das amputações de membros superiores são decorrentes de traumas (O&P Almanac, 2016; BIONICENTER, 2021). As demais possíveis causas para realização deste procedimento cirúrgico são problemas de circulação, infecções, câncer, diabetes, ou uma malformação congênita do membro. No Brasil, de acordo com o Sistema de Informações Hospitalares do Sistema Único de Saúde (SIH/SUS), entre os anos de 2015 e 2020 foram registrados mais de 10 mil procedimentos de amputações em membros superiores, dos quais 4339 foram de amputação/desarticulação de mão e punho (SIH/SUS, 2021).

A amputação pode ser considerada um evento que causa mudanças na capacidade do indivíduo realizar atividades da vida diária (AVD), podendo levar a implicações de ordem psicológica e social. Os amputados, em relação a outros grupos de pacientes, tendem a apresentar taxas mais altas de depressão, principalmente nos casos de membro superior (LUCHETTI *et al.*, 2014). Uma forma de amenizar tal situação é o uso de próteses, dispositivos projetados para substituir, totalmente ou em parte, um segmento do membro do corpo humano que seja ausente ou com deficiência (MORIMOTTO *et al.*, 2021). Elas representam um dos principais recursos que caracterizam as Tecnologias Assistivas (TA) e possibilitam a recuperação de parte das funcionalidades do membro (como exemplo, na realização de uma atividade de amarrar os cadarços de um tênis, ilustrada na figura 1), o que já se torna um grande avanço no aumento da qualidade de vida dos amputados.

Figura 1 - Utilização de prótese para realização de AVD



Fonte: Adaptado de Gruber e Lau (2014).

Os enormes avanços tecnológicos da engenharia e da computação no campo da medicina permitiram o desenvolvimento de próteses mais leves e mais adaptáveis. Em relação às próteses de membro inferior, a evolução foi tão grande que, atualmente, pessoas usuárias deste equipamento têm até participado de esportes de alto-desempenho. Já as próteses de membro superior mais modernas, do tipo mioelétricas, possuem cinco dedos e conseguem alcançar um grande número de configurações, porém a complexidade biomecânica funcional da mão tem mantido estas próteses limitadas a movimentos restritos (STOPPA e CARVALHO, 2016). Para o paciente, o controle de tal equipamento ainda é considerado inadequado, pois os sistemas possuem apenas um ou dois eletrodos de eletromiografia de superfície (sEMG) e sequências complexas de impulsos de contração muscular precisam ser realizadas para alterar o tipo de movimento a executar, ou seja, não é considerado um controle intuitivo (PATEL *et al.*, 2017), (TOMMASI *et al.*, 2013). Além disso, os altos preços dos modelos de próteses mais funcionais com valores que chegam na ordem de 20.000,00 a 100.000,00 dólares (HUMAN TECHNOLOGY, 2021; WORKCOMPWIRE, 2018) as tornam inacessíveis para a maioria dos amputados. No Brasil, esta tecnologia biônica ainda não é disponibilizada e nem coberta pelo Sistema Único de Saúde (SUS), sendo necessário o ingresso na justiça, por exemplo, via Defensoria Pública da União (DPU).

Diante deste cenário, iniciativas *open source* (CINELLI *et al.*, 2016) para o desenvolvimento de próteses de baixo custo aliadas às pesquisas sobre o desenvolvimento de sistemas de reconhecimento de padrões, capazes de identificar o movimento pretendido pelo usuário, tornam possíveis novos projetos com o objetivo de dar mais funcionalidades para as próteses e trazer impacto positivo à sociedade. Scheme e Englehart (2011) descrevem que o uso de eletromiografia (EMG) como uma fonte de controle para próteses motoras de membros superiores tem recebido considerável atenção, pois a ideia de restaurar a função através da ligação de vias neurais naturais é uma busca convincente. Diversos estudos com o uso de um maior número de sensores e técnicas mais complexas de classificação com aplicação de aprendizado de máquina têm sido realizadas e resultados com mais de 95% de acurácia já estão sendo obtidos.



Mas no mesmo artigo, Scheme e Englehart (2011) apontam alguns desafios relacionados principalmente com as diferenças entre os testes em um ambiente controlado (laboratório) e o uso clínico real. Isto pode ser observado em grande parte dos artigos sobre o tema que as pesquisas dedicam-se prioritariamente às análises comparativas entre algoritmos, mas não apresentam situações de uso em ambientes reais (LAEZZA, 2018), (ATZORI *et al.*, 2016), (NAZEMI e MALEKI, 2014). Os autores destes trabalhos expressam a integração com uma prótese como uma ideia de continuidade futura.

Altamirano (2017) comenta sobre as características que os sistemas de controle mioelétrico de membro superior devem satisfazer, entre elas: 1) o controle deve ser intuitivo para o usuário, com movimentos naturais; 2) o sistema deve ser robusto para retirar e vestir; 3) deve ser capaz de se adaptar a alterações fisiológicas, como sudorese e fadiga; 4) os algoritmos devem ter resposta rápida, menores de 300 ms. Os trabalhos de Ameri *et al.* (2018), Benatti *et al.* (2017) e Patel *et al.* (2017) apresentam classificadores no controle mioelétrico realizando experimentos de movimentos ou tarefas funcionais (manipulação de objetos) que imitam as atividades da vida diária. Estes trabalhos serviram de inspiração para a formatação dos experimentos desta tese e de estímulo na implementação de um sistema *online*.

## 1.1 QUESTÃO DE PESQUISA

Com base nas considerações anteriormente apresentadas, surge a seguinte questão de pesquisa: considerando os desafios e as características dos sistemas de controle mioelétrico descritos anteriormente quais são os requisitos necessários para o desenvolvimento de um sistema de reconhecimento de gestos e sua implantação em uma plataforma de *hardware*? Para responder esta questão, os objetivos gerais e específicos estão descritos a seguir.

## 1.2 OBJETIVOS

### 1.2.1 Objetivo geral

O objetivo desta pesquisa foi implementar um sistema de controle baseado em reconhecimento automático de padrões de movimentos mão-braço através do uso de técnicas de aprendizado de máquina aplicadas à sinais eletromiográficos. Este sistema foi implantado em uma plataforma de prototipagem de sistema embarcado para testes com prótese de baixo custo.

### 1.2.2 Objetivos específicos

Os objetivos específicos deste trabalho são:

- a) Propor, implementar e avaliar comparativamente diferentes arquiteturas/sistemas para a classificação dos dados EMG referentes aos movimentos de mão;
- b) Buscar melhorias no desempenho destes classificadores alterando hiperparâmetros;
- c) Analisar o desempenho dos classificadores com a alteração e/ou inserção de diferentes recursos e componentes;
- d) Elaborar e executar um protocolo experimental para aquisição de sinais EMG de voluntários locais e, posteriormente, rotular e formatar este banco de dados para *benchmarking* de *datasets*;
- e) Implantar em uma plataforma de prototipagem de sistema embarcado de baixo custo o classificador de melhor avaliação geral;
- f) Implementar, testar e validar os sistemas mecânico, elétrico e eletrônico de uma prótese de mão de baixo custo;
- g) Elaborar protocolos experimentais para que o(s) voluntário(s), utilizando a mão protética, possa(m) realizar testes de preensão e deslocamento de objetos;
- h) Avaliar os resultados dos experimentos e propor melhorias nos sistemas implementados.

### 1.3 DELIMITAÇÕES DO TRABALHO

Nesta tese o sistema implementado levou em consideração a classificação de movimentos e acionamento de uma prótese para pessoas com amputação transradial ou com desarticulação de pulso. Para cada classe, foram aplicadas rotinas pré-formatadas para o movimento pretendido.

### 1.4 JUSTIFICATIVAS

O projeto de uma prótese de mão pode ser considerado um problema multidisciplinar, envolvendo no mínimo três grandes áreas: saúde, engenharia e computação, desde as especificações de materiais, os projetos dos sistemas mecânico, elétrico (acionamentos elétricos e motores) e de instrumentação eletroeletrônica (sensores mioelétricos) e do processamento digital de sinais (aquisição de dados, rotulagem, pré-processamento, classificação e decisor). Esta tese explorou o trabalho nestes três campos iniciando por uma revisão bibliográfica dos assuntos biomecânica da mão e eletromiografia, após a implementação e testes de um protótipo de uma prótese de mão de baixo custo selecionando os sistemas de aquisição e processamento de sinais com base em critérios estabelecidos e por fim o desenvolvimento do sistema embarcado (com as etapas de processamento descritas acima) para o acionamento da mão protética.

Como contribuições deste trabalho, podemos citar em primeiro lugar a entrega de um protótipo de equipamento para Tecnologia Assistiva através da proposição de uma plataforma completa e versátil de *hardware* e *software* de baixo custo incorporando as etapas de aquisição de sinais, pré-processamento, processamento com rotina para leitura *in loop* de janelas de sinais EMG, classificação utilizando Aprendizado de Máquina e circuito de decisão, sistema de acionamento da prótese motora. A segunda contribuição é a própria investigação e testes das arquiteturas para classificação de sinais EMG e (alguns) fatores que podem influenciar no desempenho dos classificadores, sendo os ensaios validados de forma *offline* através do processamento de duas bases de dados públicas NinaPro. O protocolo experimental para aquisição de sinais eletromiográficos, a criação de um banco de dados EMG de voluntários locais e os protocolos para

testes de prensão e deslocamento são também contribuições desta tese. E através desta plataforma e da primeira versão de nosso banco de dados EMG, disponibilizando todos os algoritmos e rotinas desenvolvidas de pré-processamento, rotulagem do *dataset*, cálculo de *features* e classificação, temos o intuito de auxiliar diferentes grupos de estudo em suas pesquisas e experimentos de reconhecimento de gestos/movimentos de mão, a fim de melhorar o desempenho dos classificadores e desenvolver novos sistemas de controle de próteses mioelétricas.

## 1.5 METODOLOGIA

Esta tese se caracteriza como uma pesquisa de caráter exploratório (PRODANOV e DE FREITAS, 2013), pois tem como finalidade proporcionar mais informações sobre o problema que será investigado para posteriormente construir hipóteses na busca de uma solução verificada através da experimentação. Quanto aos procedimentos metodológicos, esta tese pode ser caracterizada como experimental (GERHARDT e SILVEIRA, 2009), pois visa a criação de um protótipo de *hardware* e *software* com a finalidade de realizar reconhecimento de movimentos através de Aprendizado de Máquina. Com base em Wazlawick (2014), a metodologia de trabalho adotada possui as seguintes etapas: a) realização de revisão bibliográfica sobre anatomia da mão, eletromiografia e próteses; b) realização de estudo e análise de trabalhos relacionados que compreendem o estado da arte do objeto de pesquisa desta proposta de tese; c) desenvolvimento de protótipo (*hardware* e *software*); d) coleta de dados, pré-processamento e validação do modelo; e) realização de experimentos para avaliar os resultados possíveis; f) descrição e documentação da pesquisa.

## 1.6 ORGANIZAÇÃO DO TEXTO

Esta tese está estruturada da seguinte forma: o capítulo 2 apresenta os conceitos sobre anatomia da mão humana, próteses de mão e eletromiografia e informações de controle de próteses e classificação de movimentos de mão-punho através de sinais EMG. O capítulo 3 descreve os sistemas de classificação de sinais EMG. O capítulo 4 busca oferecer uma visão das pesquisas relacionadas aos temas

classificação de padrões e controle mioelétrico. O capítulo 5 apresenta a metodologia deste trabalho, informando as configurações dos algoritmos e hiperparâmetros a serem ajustados para implementação da classificação, os bancos de dados e os movimentos de mão selecionados, o sistema de aquisição de sinais EMG, a metodologia de criação de um banco de dados EMG de voluntários locais, o protótipo da mão protética, os experimentos para validação do sistema e os métodos e métricas para sua avaliação. O capítulo 6 apresenta os resultados obtidos e discussões dos experimentos realizados. Por fim, no último capítulo, são apresentadas as conclusões e considerações finais, novas etapas em desenvolvimento para otimizar este sistema e propostas para continuidade desta pesquisa.

## 2 FISILOGIA HUMANA, PRÓTESES DE MÃO E ELETROMIOGRAFIA

Este capítulo apresenta a descrição das estruturas esquelética e muscular da mão humana, seus movimentos funcionais, a amputação de membros e a alternativa do uso de próteses, levando em consideração modelos comerciais, alternativas *open source* e pesquisas acadêmicas e por último o processo de aquisição de sinais eletromiográficos.


### 2.1 CONSIDERAÇÕES SOBRE A MÃO HUMANA

A mão humana é uma ferramenta capaz de desempenhar muitas Atividades da Vida Diária (AVD) devido à sua principal função, a preensão, que permite a manipulação de inúmeros objetos (RAZZA e PASCHOARELLI, 2009). Engelberg (1990) cita ainda que os dedos da mão são tão vitais na realização das AVDs que um indivíduo que não os possui é considerado 54% capaz em relação a uma pessoa com todos os membros intactos. Do ponto de vista fisiológico a mão não é somente um órgão de execução, mas também o receptor funcional extremamente sensível e preciso (KAPANDJI, 2000). Nesta seção são apresentadas informações sobre a anatomia da mão, tipos de preensão, próteses comerciais e *open source*.

#### 2.1.1 Aspectos anatômicos

A mão é formada por vinte e sete ossos (figura 2), dezessete articulações e quarenta músculos. Os ossos da mão se dividem em três partes: carpo (punho), metacarpo e falanges. O punho possui oito ossos divididos em duas fileiras: proximal e distal. Na fileira Proximal estão o Escafoide, o Semilunar, o Piramidal e o Pisiforme; A fileira distal inclui o Trapézio, o Trapezoide, o Capitato e o Hamato. A mão tem cinco ossos longos, chamados de ossos metacarpiais e cada um dos cinco dedos possui um conjunto de falanges proximal, média e distal (com exceção do polegar que não possui falange medial) (NETTER, 2011), (NEUMANN, 2006).

Figura 2 - Ossos do punho e mão



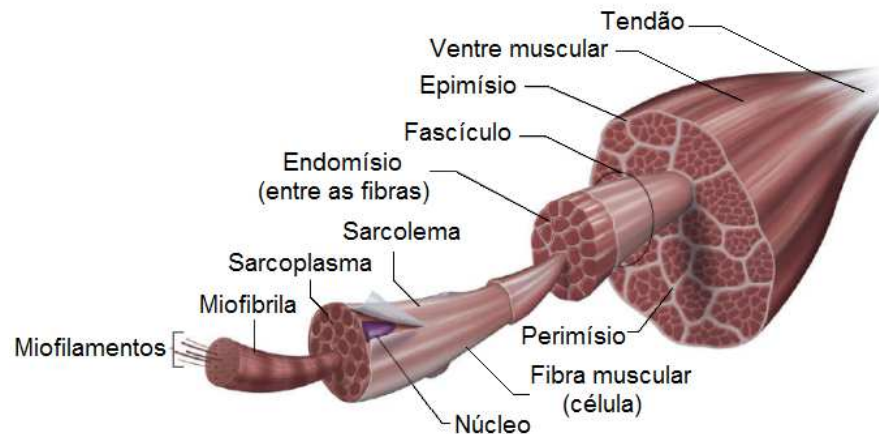
Fonte: Adaptado de Gilroy e MacPherson (2017).

Esta gama de elementos dá a ela vinte e três graus de liberdade (DOF - *degrees of freedom*), sendo 5 para o polegar, 4 para cada um dos demais dedos e dois para a palma da mão. Levando em consideração toda a estrutura da mão, podemos descrever os seus principais movimentos funcionais.

### 2.1.2 Fisiologia do músculo esquelético

O elemento responsável pela geração de força e movimento corporal é o músculo. Estas forças musculares agem por meio de um sistema de alavancas ósseas tornando possível diversas atividades como locomoção e a manipulação de objetos. Cerca de 40% da massa corporal é composta por músculo esquelético (GUYTON, 2017). A figura 3 apresenta a estrutura de um músculo esquelético.

Figura 3 - Estrutura de um músculo esquelético



Fonte: Adaptado de Haff e Triplett (2016).

O músculo esquelético é composto por vários fascículos (feixes), e estes são formados por células chamadas de fibras musculares, que possuem formato cilíndrico com diâmetros variando entre 10 e 80  $\mu\text{m}$  (GUYTON, 2017). Cada fibra muscular é constituída por centenas de miofibrilas, núcleos celulares e pelo retículo sarcoplasmático, envoltos em uma membrana plasmática, chamada de sarcólema (BELTRAMINI, 1999), (GUYTON, 2017).

Existem dois tipos de contração muscular: a isométrica e a isotônica. A contração isométrica, também chamada de estática ou de sustentação, não provoca movimento ou deslocamento muscular, havendo apenas registro de tensão gerada pela contração (HALL, 2016). A contração isotônica, também conhecida como dinâmica, provoca o movimento articular com alteração do comprimento do músculo mas sem alterar sua tensão máxima (GUYTON, 2017). Esta contração isotônica se divide-se em dois tipos: contração concêntrica (dinâmica positiva) e contração excêntrica (dinâmica negativa). Na ação concêntrica, a força produzida pelo músculo é maior que a resistência oferecida, ocorrendo o encurtamento do músculo. E na contração excêntrica a tensão gerada em um músculo é menor que a carga imposta, ocorrendo o seu alongamento (HALL, 2016).

### 2.1.3 Movimentos funcionais da mão




A mão humana é um dos mecanismos mais complexos do corpo humano, capaz de realizar vários movimentos. Dentre estes movimentos, a preensão é considerada a função mais essencial da mão, pois ela dá ao ser humano a capacidade de agarrar e segurar os mais diversos objetos.



Existem diversas classificações para as preensões levando em considerações diferentes critérios como manipulação, força de fechamento, deslizamento do objeto precisão dos movimentos, número de dedos na execução da preensão, entre outros. Napier (1956) estudou os movimentos da mão e definiu duas classes principais: preensão de precisão e preensão de força.

Já o estudo de Kapandji (2000) classificou os movimentos de preensão em 3 grandes grupos: as preensões propriamente ditas, as preensões com a gravidade e as preensões com ação. As preensões propriamente ditas se classificam em três subgrupos: preensões digitais, palmares e centradas, mostrados na figura 4.

Figura 4 - Tipos de preensões digitais, palmares e centrais

PREENSÕES DIGITAIS		PREENSÕES PALMARES	PREENSÕES CENTRAIS
PINÇAS BIDIGITAIS	PINÇAS PLURIDIGITAIS		
Terminal 	Trigital da polpa 	Digital - palmar 	
Subterminal 	Tetradigital da polpa 	Palmar com toda a mão 	
Subterminal lateral 	Pentadigital da polpa 	Palmar cilíndrica 	

Fonte: Adaptado de Kapandji (2000) e Mateo (2015).

As preensões ou pinças digitais podem ser divididas em dois subgrupos: as preensões bidigitais e as preensões pluridigitais. As preensões bidigitais constituem a clássica pinça polegar-dedos, geralmente polegar-dedo indicador. Elas, por sua vez, apresentam três tipos segundo a oposição: 1) a preensão feita por oposição terminal é a mais fina e precisa, onde o polegar e o dedo indicador (ou o médio) realizam a oposição pela extremidade da polpa (e em casos de objetos extremamente finos a utilização da ponta da unha). 2) a preensão por oposição subterminal ou com a ponta dos dedos é o tipo mais comum. Ela permite segurar objetos relativamente mais grossos como um lápis ou uma folha de papel. 3) a preensão por oposição subterminal lateral pode substituir a oposição terminal ou a subterminal quando as duas últimas falanges do dedo indicador foram amputadas. Esta pinça é menos delicada embora continue sendo firme. Já as preensões pluridigitais permitem uma preensão muito mais firme que a bidigital, pois além do polegar são utilizados dois, três ou quatro dedos.

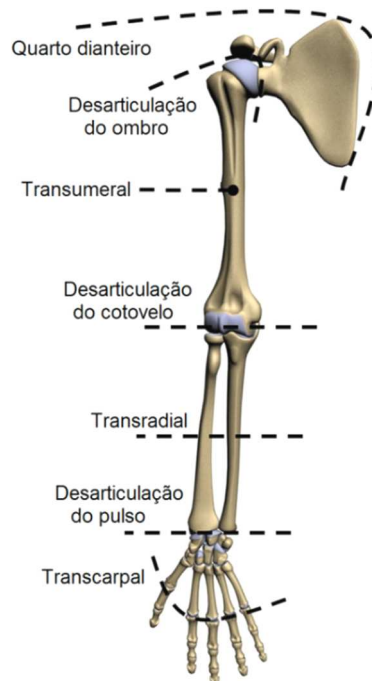
Nas preensões palmares participa, além dos dedos, a palma da mão. São dois tipos, dependendo do uso ou não do polegar: 1) a preensão dígito-palmar não utiliza o polegar. Ela realiza a oposição da palma da mão com os últimos quatro dedos, sendo utilizada na forma de uma alavanca. 2) a preensão palmar com toda a mão e palmar cilíndrica utiliza o polegar em oposição a palma. São as preensões de força para os objetos relativamente volumosos e pesados. A mão literalmente se enrola em torno do objeto. As preensões centradas realizam um movimento simétrico em torno do eixo longitudinal que é confundido, em geral, com eixo do antebraço. Em todos os casos, o objeto de forma alongada é seguro com firmeza através da preensão palmar que utiliza o polegar e os últimos três dedos, com o indicador desempenhando um papel direcionador essencial para orientar o utensílio.

Além das preensões sem atuação da gravidade, já descritas, apresentamos o grupo onde ela é indispensável. Neste tipo de preensão, a mão serve de suporte, como quando seguramos uma bandeja, o que supõe que ela consegue ficar com a palma na posição horizontal e orientada para cima. A última classificação do grande grupo de preensões é a de mais movimentos (também chamado de preensões com ação) onde a mão também é capaz de agir segurando. Dentre os exemplos, citamos a ação de cortar com a tesoura, de apertar a tampa de um frasco ou acender um isqueiro.

### 2.1.4 Amputação

O termo amputação se refere à cirurgia para retirada total ou parcial de um dos membros. De acordo com os dados do Ministério da Saúde (2013) relativos a 2011, as principais causas de amputações realizadas pelo SUS (Sistema Único de Saúde) estavam relacionadas a causas externas, doenças infecciosas e parasitárias, doenças do aparelho circulatório, diabetes e doenças do sistema osteomuscular e do tecido conjuntivo. Estima-se que as amputações de membros superiores correspondem a 15% de todas as amputações ocorridas (MINISTÉRIO DA SAÚDE, 2013). Cordella *et al.* (2016) definem os diferentes níveis de amputação do membro superior como transcarpal, desarticulação do pulso, transradial, desarticulação do cotovelo, transumeral, desarticulação do ombro e quarto dianteiro. A figura 5 ilustra os possíveis níveis de amputação.

Figura 5 - Níveis de amputação do membro superior



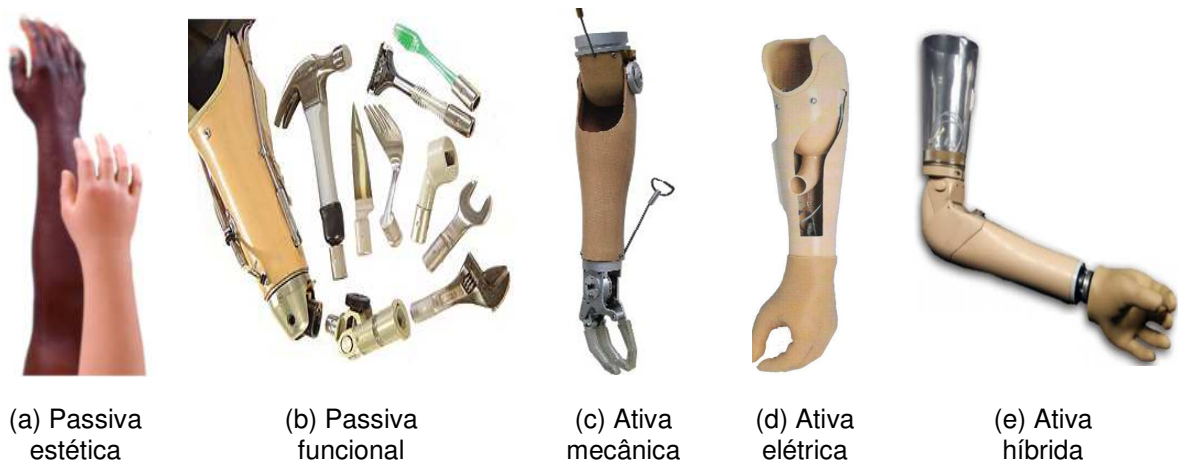
Fonte: Adaptado de Cordella *et al.* (2016).

Durante o processo de reabilitação de pacientes amputados, o uso de próteses passa a ser uma alternativa para a restauração da capacidade de realização de Atividades da Vida Diária (AVD) (CINELLI *et al.*, 2016). O coto é o membro residual após a amputação, podendo ser o membro responsável pelo controle de próteses (PASTRE *et al.*, 2005). Na seção seguinte são apresentadas informações sobre classificação e os tipos de próteses para membro superior, com foco em próteses de mão.

## 2.2 PRÓTESES PARA MEMBRO SUPERIOR

De acordo com Wright *et al.* (2001) podemos classificar as próteses levando em consideração o nível de amputação do usuário e sua fonte de energia. A figura 6 apresenta as duas principais categorias quanto ao tipo de energia: próteses passivas (divididas em estéticas e funcionais) e próteses ativas (divididas em mecânicas, elétricas e híbridas).

Figura 6 - Próteses passivas e ativas



Fonte: Adaptado de OttoBock (2018), Texas Assistive Devices (2018) e Ethnos (2018).

As próteses estéticas (figura 6.a) visam principalmente a substituição estética do membro perdido, enquanto as próteses funcionais (figura 6.b) têm como propósito facilitar a realização de atividades muito específicas, relacionadas por exemplo a um trabalho ou prática de algum esporte (CORDELLA, 2016). Nas próteses mecânicas (figura 6.c) o movimento do corpo do usuário tensiona um sistema de cabos que, então aciona o cotovelo, a mão ou um gancho (WRIGHT *et al.*, 2001). Já as próteses elétricas (figura 6.d), elas podem ser controladas por botões externos ou por sinais EMG provenientes das contrações musculares, esses sinais são captados por meio de eletrodos, após são filtrados, amplificados e transmitidos ao processador do sistema (CORDELLA *et al.*, 2016). Sobre a prótese híbrida (figura 6.e), ela é a combinação de 2 tipos de controle na mesma prótese (por exemplo, um cotovelo mecânico e uma mão mioelétrica). A seguir são apresentadas informações de próteses comerciais e projetos *open source* considerando suas principais características e funcionalidades.

### 2.2.1 Próteses comerciais

A maioria das próteses de mão comerciais de última geração utilizam a técnica de eletromiografia para seu controle e possuem cinco dedos que são acionados individualmente por motores elétricos (GEETHANJALI, 2016). Seus projetos apresentam sistemas de controle avançados propiciando movimentos mais precisos e utilizam novos materiais permitindo dispositivos mais leves, com maior resistência mecânica e uma grande semelhança com a mão natural. Atzori e Müller (2015) apresentaram um panorama da realidade tecnológica destas próteses comerciais incluindo uma análise comparativa entre alguns modelos. Três dos modelos mais conhecidos de prótese de mão são mostrados na figura 7 e suas principais características são descritas a seguir.

Figura 7 - Prótese de mão comerciais



(a) i-Limb Quantum

(b) Bebionic3

(c) Taska

Fonte: Adaptado de Bebionic (2018), Touch Bionics (2018) e Taska (2018).

A primeira prótese apresentada é a i-Limb Quantum® (TOUCH BIONICS, 2018), produzida pela empresa islandesa Össur. Possui 5 motores independentes (1 para cada dedo), permitindo alterar a força de preensão dedo por dedo, pode realizar 24 movimentos pré-configurados, detecção de deslizamento de objetos e ajuste automático de força e três formas de configuração: por gesto, por aplicativo para celular, por proximidade e por atividade muscular (com 2 sensores mioelétricos). A figura 7.a apresenta duas versões da prótese i-Limb Quantum. Este modelo de prótese ainda apresenta a possibilidade de cadastramento de

movimentos personalizados (através de *software* Biosimcom, fornecido pela empresa) e possui uma luva, para mascarar os mecanismos da prótese, dando uma aparência mais próxima da mão natural.

A segunda prótese, mostrada na figura 7.b, é a Bebionic3® (BEBIONIC, 2018) comercializada pela empresa alemã OttoBock. Com ela, o usuário é capaz de realizar 14 movimentos de mão (que são pré-programados através de comunicação Bluetooth) e de levantar um peso equivalente a 45 kg. Possui como características principais: sensores de força em cada dedo para ajuste da força de preensão, função aderência (detecção se o objeto está escorregando e ajuste da força), configurações de velocidade de movimento, do tempo de reação entre os comandos, do número de eletrodos utilizados (1 ou 2), tipo de informação de retorno para o usuário (sonoro ou motor vibratório), e estratégia de acionamento por sequência de movimentos. Também possui luva estética em 3 tamanhos e 20 tonalidades de pele.


E a terceira prótese, mostrada na figura 7.c, é o modelo Taska® (TASKA PROSTHETICS, 2017) distribuída pela empresa americana Motion Control (divisão Fillauer). Possui como principais características a realização de 23 movimentos que podem ser acionados por botão ou sinais EMG (dois eletrodos) e proteção contra poeira e água (certificação IP67). Este modelo ainda realiza movimentos laterais dos dedos permitindo que a mão segure com firmeza uma grande variedade de objetos. E o usuário consegue personalizar cinco movimentos através de aplicativos iOS e Android.

Em consequência das tecnologias empregadas nestas próteses comerciais apresentadas, seus custos são extremamente altos, na ordem de 20.000,00 a 100.000,00 dólares dependendo do nível de customização requerido (HUMAN TECHNOLOGY, 2021; WORKCOMPWIRE, 2018), impedindo que grande parte da população com necessidade de uso de próteses consiga adquirir um destes modelos. Desta forma, movimentos de projetos de próteses *open source* vêm se popularizando nos últimos anos.

### 2.2.2 Próteses de baixo custo *open source*

Nesta seção, são apresentados três dos mais populares projetos *open source* de próteses de mão: Brunel 2.0 (OPEN BIONICS, 2018), inMoov (LANGEVIN, 2018) e HACKberry (EXIII, 2018). Estes projetos, mostrados na figura 8, disponibilizam de forma gratuita, seus arquivos de impressão para *download*.

Figura 8 - Prótese de mão *open source*



Fonte: Adaptado de Open Bionics (2018), Langevin (2018) e Exiii (2018).

A mão Brunel 2.0, lançada pela *startup* inglesa Open Bionics, possui 9 DOF, peso de 332 gramas e inclui para download todos os arquivos do sistema mecânico, da placa de circuito impresso (PCI) e do firmware. Utiliza o mesmo microcontrolador da plataforma Arduino sendo compatível com todo seu ambiente de programação. Para impressão são utilizados os materiais PLA (Ácido polilático) e TPU (Poliuretano termoplástico) possuindo almofadas de uretano na palma e nos dedos para maior aderência na pega de objetos. Além disso, o sistema dispõe de realimentação de corrente para determinar a força de preensão dos dedos da prótese.

O segundo sistema *open source* descrito é o projeto InMoov (figura 7.b) criado pelo escultor e designer francês Gaël Langevin. A plataforma apresenta o desenvolvimento de um robô humanóide em tamanho real para impressão 3D, onde suas peças estão disponibilizadas via web em formato STL - *Standard Tessellation Language*. O projeto do braço assemelha-se muito ao braço humano em relação aos seus movimentos e estética. No caso da mão, possui cinco dedos independentes e seis servomotores que são responsáveis pela movimentação de cada dedo e do pulso, totalizando 17 DOF. Os tendões do corpo humano são substituídos por fios de

nylon, que conectados aos servomotores, são responsáveis pelo movimento de cada dedo da prótese (LANGEVIN, 2018).

A prótese de mão HACKberry, mostrada na figura 7.c, foi lançada pela *startup* japonesa Exiii Inc. em 2015. É um protótipo que utiliza uma pulseira de sensores infravermelhos (modelo TPR-105) no lugar de sensores mioelétricos, bateria de câmera digital e possui um pulso flexível. Seus dedos são parcialmente motorizados (através de três servomotores: um para o polegar, um para o dedo indicador e um para os outros três dedos) e o acionamento elétrico é realizado através de um controlador Arduino (Pro Micro), todos estes dispositivos alojados em um invólucro de plástico branco impresso em 3D. Seus arquivos para impressão estão disponíveis no site GitHub<sup>2</sup>.

## 2.3 ELETROMIOGRAFIA

A eletromiografia é uma técnica utilizada para capturar as atividades elétricas geradas pelos músculos esqueléticos obtendo sinais elétricos chamados de sinais eletromiográficos (EMG), permitindo o registro e a avaliação dos sistemas neuromuscular e músculo-esquelético. Além do seu uso no controle de próteses, também é utilizado em diversos outros fins como Fisioterapia, Odontologia, Medicina, Fonoaudiologia, permitindo aplicações em análises clínicas e acompanhamento de tratamentos (GODOI *et al.*, 2013), (KONRAD, 2006).

### 2.3.1 Unidade motora

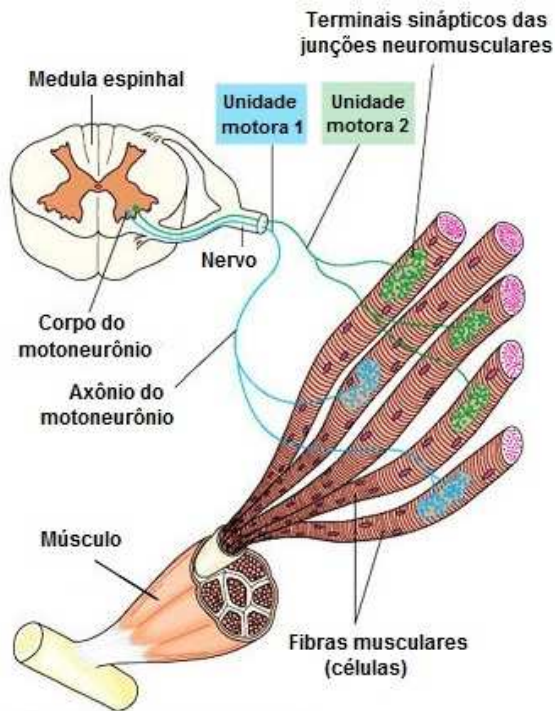
A unidade motora ou MU (*Motor Unit*) é a menor unidade muscular controlável. Ela é constituída por um conjunto de fibras musculares que são inervadas em um motoneurônio, também chamado de motoneurônio-alfa (DE LUCA, 2006). Uma única unidade motora pode conter menos de 100 até 2000 fibras musculares, dependendo do tipo de movimento e da força requerida pelo músculo (HALL, 2016). A figura 9 mostra a representação esquemática de uma unidade motora e seus componentes.

---

<sup>2</sup><http://github.com>



Figura 9 - Representação dos elementos básicos do controle motor

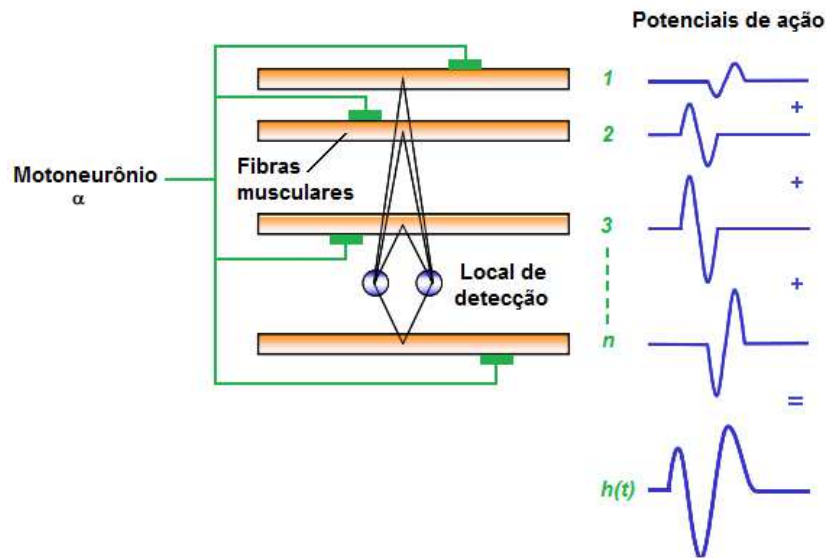


Fonte: Adaptado de Mallery (2018).

A MU consiste em três componentes principais: os corpos celulares dos motoneurônios, localizados na medula espinhal, que são os responsáveis pela criação do potencial de ação. Junto ao corpo celular do motoneurônio estão os axônios cuja função é transportar o sinal da medula para as fibras musculares. E a terceira componente é a fibra muscular que reage ao potencial de ação realizando a contração do músculo.

A soma algébrica, no tempo e espaço, dos potenciais de ação gerados pelas  $n$  fibras de uma unidade motora é chamada de Potencial de Ação da Unidade Motora ou MUAP (*Motor Unit Action Potential*) (BASMAJIAN e DE LUCA, 1985). A figura 10 apresenta uma representação esquemática da formação da MUAP indicado por  $h(t)$ .

Figura 10 - Esquema de formação de uma MUAP



Fonte: Adaptado de Konrad (2005).

O MUAP gerado por diferentes fibras musculares não ocorre de forma sincronizada, ou seja, nem todas as fibras musculares são estimuladas ao mesmo tempo. Isto se deve, entre outros fatores, a diferentes tempos de propagação sobre as ramificações dos axônios no motoneurônio (GUYTON, 2017). A amplitude de um MUAP é de  $100 \mu\text{V}$  a  $5 \text{ mV}$  com duração de 2 a 10 ms e banda de frequência de 5 Hz a 10 kHz (SÖRNMO e LAGUNA, 2005).

Devido a este tempo de duração da MUAP, as UM precisam ser ativadas repetitivamente para sustentar uma contração muscular por maiores períodos. Esta sequência de MUAPs é chamada de Trem de Potenciais de Ação da Unidade Motora (MUAPT - *Motor Unit Action Potential Train*).

### 2.3.2 Sinais EMG e sua detecção

A detecção dos sinais mioelétricos pode ser realizada através de eletrodos invasivos (intramusculares) ou eletrodos de superfície (sEMG). A seleção de um tipo de eletrodo depende do tipo de músculo a ser estudado. Para músculos mais profundos são utilizados eletrodos invasivos (de tipo agulha ou fio) sendo possível obter os potenciais de ação individuais da fibra muscular (DE LUCA, 2006). Já os eletrodos de superfície são colocados sobre a pele. Tem como vantagem seu fácil manuseio e maior conforto para o paciente, pois não possui agulha ou fio como os


sensores invasivos. Sua desvantagem é a possibilidade da detecção de sinais elétricos oriundos de músculos vizinhos conhecida como *crosstalk* (DE LUCA, 2006). Mesmo assim, GAZZONI *et al.* (2014) afirmam que a eletromiografia de superfície é o padrão ouro no estudo do movimento das mãos e dos dedos através da análise da ativação muscular e com aplicações no controle de próteses, reabilitação e ergonomia.

Os sEMG podem ser compostos de metais nobres como ouro (Au), prata (Ag) e cloreto de prata (AgCl) sendo os eletrodos Ag/AgCl os mais utilizados. São combinados com um gel ou pasta condutora com o objetivo de reduzir a impedância entre o eletrodo e a pele. E ainda, para reduzir a quantidade de interferências no sinal EMG, deve ocorrer o tratamento da pele, iniciando com a remoção dos pelos na região de interesse e a limpeza com álcool (KONRAD, 2006).

Os eletrodos de superfície possuem amplitudes de 50  $\mu\text{V}$  até 5 mV com frequências na faixa de 20 Hz a 500 Hz mas com a maior parte da energia dominante entre 50 Hz e 150 Hz (DE LUCA, 2002). Fridlung e Cacioppo (1986) afirmam que, em geral, a energia primária do sinal de sEMG está entre 10 Hz e 200 Hz, entre 10 Hz e 30 Hz a potência é devida, em grande parte, às taxas de disparo das unidades motoras e acima de 30 Hz ocorre a ação das MUAPs.

A aquisição do SME através dos eletrodos pode ocorrer através de duas configurações: monopolar e bipolar. Na configuração monopolar são utilizados dois eletrodos: um de sinal e um de referência. O potencial elétrico é obtido pela diferença de potencial entre esses dois pontos. Tem a desvantagem de detectar sinais indesejáveis de músculos de regiões adjacentes (DE LUCA, 2006). Na configuração de detecção bipolar, mostrada na figura 11, são utilizados três eletrodos, onde dois eletrodos são posicionados na direção longitudinal em relação as fibras musculares da região de interesse, detectando assim dois potenciais ( $m_1$  e  $m_2$ ) no tecido muscular, cada um em relação ao eletrodo de referência. Junto com os sinais temos o ruído  $n$  que é atenuado através de um amplificador diferencial.

Figura 11 - Eletrodos ativos com amplificador diferencial




Fonte: Adaptado de De Luca (2002).

Estes dois sinais são enviados para um amplificador diferencial que amplifica a diferença de potencial elétrico entre estes dois eletrodos e atenuando  $n$  ruídos do sistema e do ambiente (DE LUCA, 2006).

### 2.3.3 Banco de dados NinaPro

O projeto NinaPro (***Non-Invasive Adaptive Hand Prosthetics***) é um repositório de dados de sinais EMG que inclui tanto indivíduos amputados quanto não amputados. O *dataset* visa apoiar a comunidade científica em pesquisas de controles de próteses mioelétricas (GIJSBERTS *et al.*, 2014). Além da atividade muscular adquirida através de eletrodos de superfície (figura 12), onde a quantidade de eletrodos depende do banco de dados, foram utilizados sensores de inclinação e acelerômetros para o registro da cinemática da mão.

Figura 12 - Posicionamentos dos eletrodos superficiais no braço



Fonte: Adaptado de Gijssberts *et al.* (2014).

Durante a aquisição dos sinais, os participantes estavam sentados e repetiam os movimentos que foram mostrados na tela de um computador. O experimento foi dividido em três exercícios: a) movimentos básicos dos dedos, b) posturas da mão (isométricas e isotônicas) e movimentos básicos do pulso e c) agarramento e movimentos funcionais. Então, os sinais produzidos foram capturados, registrados e pós-processados para o banco de dados. Para cada participante e exercício, o banco de dados contém um arquivo no formato .MAT (formato do Matlab®) com as seguintes variáveis apresentadas no quadro 1 (PIZZOLATO *et al.*, 2016), (ATZORI *et al.*, 2014a):

Quadro 1 - Variáveis do banco de dados NinaPro

Variáveis	Descrição
<i>subject</i>	Número de identificação do sujeito.
<i>exercise</i>	Número do exercício.
<i>emg</i>	Matriz de $M$ linhas x $N$ colunas, onde cada linha apresenta uma amostra no tempo e cada coluna apresenta o valor de um dos eletrodos de superfície (a quantidade de colunas depende do banco de dados).
<i>acc</i>	Matriz $M$ linhas x $N$ colunas, onde cada linha apresenta uma amostra no tempo e cada coluna apresenta o valor do sinal de cada um dos três eixos do acelerômetro.
<i>stimulus</i>	Matriz de $M$ linhas x 1 coluna, onde cada linha apresenta uma amostra no tempo do movimento realizado pelo sujeito.
<i>repetition</i>	Matriz de $M$ linhas x 1 coluna, onde cada linha apresenta uma amostra no tempo do número de repetição do movimento realizado pelo sujeito.
<i>restimulus</i>	Matriz <i>stimulus</i> processada com algoritmo de detecção de movimento.
<i>rerepetition</i>	Matriz <i>repetition</i> processada com algoritmo de detecção de movimento.

Fonte: adaptado de ATZORI *et al.* (2014a).

Atualmente são 9 bases de dados publicadas no repositório NinaPro, nomeadas de DB1 a DB9. Estas bases de dados se diferenciam pelo tipo e número de movimentos, quantidade de repetições destes movimentos, taxa de aquisição, resolução dos sistemas de aquisição, número e local de fixação dos eletrodos e tipo de indivíduo (amputado e não amputado). A tabela 1 apresenta um resumo das principais características das bases de dados NinaPro.

Tabela 1 - Características dos *datasets* NinaPro

<b>Datasets</b>	<b>Indivíduos</b>	<b>Eletrodos</b>	<b>Número de movimentos</b>	<b>Número de repetições</b>	<b>Resolução (bits)</b>
<b>DB1</b>	27 N (20 M e 7 F)	10 (OttoBock)	52	10	12
<b>DB2</b>	40 N (28 M e 12 F)	12 (Delsys)	49	6	16
<b>DB3</b>	11 A (11 M)	12 (Delsys)	49	6	16
<b>DB4</b>	10 N (6 M 4 F)	12 (Cometa Systems)	52	6	16
<b>DB5</b>	10 N (8 M 2 F)	16 (Thalnic Labs)	52	6	8
<b>DB6</b>	10 N (7 M 3 F)	14 (Delsys)	7	24	16
<b>DB7</b>	20 N 2A	12 (Delsys)	40	6	16
<b>DB8</b>	10 N 2 A	16 (Delsys)	9	12	16
<b>DB9</b>	77 N	*	41	*	*


Nota: A (amputado); N (não amputado); M (masculino); F (feminino);

\* De acordo com os bancos de dados DB1, DB2 e DB5 incorporados a este *dataset*


Fonte: Adaptado de Phinyomark e Scheme (2018) e Jarque-Bou *et al.* (2020).

Os bancos de dados DB2 e DB3 incluem dados de eletromiografia e acelerometria relacionados aos movimentos e gestos das mãos. O conjunto de dados DB2 inclui aquisições de dados EMG e ACC de 40 indivíduos intactos (12 mulheres, 28 homens; 34 destros, 6 canhotos). O banco de dados DB3 inclui aquisições de dados de 11 amputados transradiais (11 homens: 10 destros, 1 canhoto). Cada sujeito realizou 49 movimentos (8 configurações isométricas e isotônicas da mão; 9 movimentos básicos do punho; 23 movimentos de preensão e funcionais e 9 padrões de força). Nessas bases de dados, os sinais EMG foram adquiridos usando 12 eletrodos ativos (da marca Delsys) na configuração de par diferencial com uma taxa de amostragem de 2 kHz. Um conjunto de oito sensores foram colocados ao redor do antebraço, igualmente espaçados, dois eletrodos foram colocados nos músculos de flexão e extensão do dedo e dois sensores foram colocados nos principais pontos de atividade do bíceps e tríceps braquial. Cada eletrodo tem um acelerômetro de três eixos amostrado a 148 Hz, que totaliza 36 canais (12 eletrodos x 3 eixos). Cada movimento foi repetido seis vezes com um tempo de descanso de 3 segundos entre eles (ATZORI *et al.*, 2014a e ATZORI *et al.*, 2015). A figura 13 apresenta os 49 movimentos da base de dados NinaPro DB2.

Figura 13 - Movimentos realizados no NinaPro DB2



(a) 8 movimentos básicos dos dedos (flexões e extensões)



(b) 9 movimentos básicos de pulso



(c) 23 movimentos funcionais



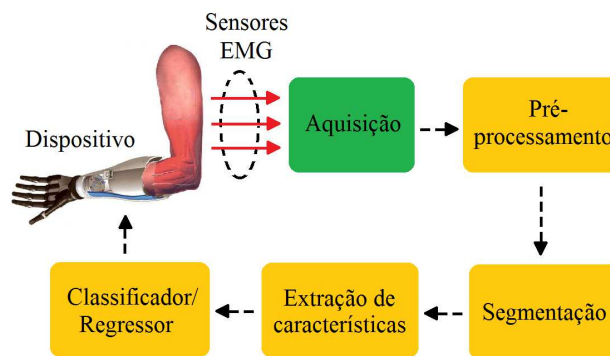
(d) 9 posturas de mão

Fonte: adaptado de ATZORI *et al.* (2014a).

### 2.3.4 Classificação de sinais EMG

Para o controle de uma prótese de mão, existe a necessidade de utilizar um sistema de reconhecimento de padrões, capaz de identificar que tipo de movimento o usuário deseja proceder. Um sistema de reconhecimento de padrões (PR - *Pattern Recognition*) exige uma série de etapas: aquisição dos sinais EMG, pré-processamento, segmentação, extração de características e algum algoritmo de classificação ou regressão. Esta é a chamada abordagem clássica de um PR, mostrada na figura 14 (AMERI *et al.*, 2018).


Figura 14 - Abordagem clássica para reconhecimento de padrões EMG



Fonte: Adaptado de Ameri *et al.* (2018).

Existe ainda a abordagem baseada em aprendizagem profunda (figura 15) onde podemos citar as Redes Neurais Convolucionais (*Convolutional Neural Networks* - CNNs) e as Redes Neurais Recorrentes (*Recurrent Neural Networks* - RNNs) (AMERI *et al.*, 2018), (PHINYOMARK e SCHEME, 2018).

Figura 15 - Abordagem para reconhecimento de padrões EMG baseada em aprendizagem profunda




Fonte: Adaptado de Ameri *et al.* (2018).



Na etapa pré-processamento, comum às duas abordagens, os sinais são filtrados para atenuar os artefatos de movimento e ruídos de alta frequência, retificados e normalizados. Outro bloco de um PR é a segmentação dos dados de cada conjunto. Esta etapa tem como objetivo a separação dos dados EMG em intervalos para o cálculo/extração das *features* e estes intervalos devem conter informações suficientes para estimar um movimento e ser capaz de realizar a operação em tempo real (OSKOEI e HU, 2008). Entre os métodos de segmentação, o janelamento é o mais utilizado nos sistemas de reconhecimento de movimentos/gestos de mão através da eletromiografia para o controle de próteses elétricas (CENE e BALBINOT, 2018). A técnica de janelamento é classificada em janelas de tempo adjacentes e em janelas de tempo sobrepostas. Nas janelas de tempo adjacentes, o sinal é segmentado com comprimentos pré-definidos realizando a extração das *features* e classificação após um certo atraso de processamento. Ao final desta janela, outra janela é iniciada e o sistema computacional aguarda o seu término para novamente realizar a execução dos cálculos de *features* e predição, desta forma subutilizando o sistema de processamento (ENGLEHART e HUDGINS, 2003). Nas janelas de tempo sobrepostas, o novo segmento desliza sobre o segmento atual e o tempo de incremento é menor que o comprimento da janela (NAZMI *et al.*, 2016), ou seja, esta etapa consiste em amostrar o sinal a partir de janelas de tempo com tamanhos ( $T_a$ ) e incrementos ( $T_{inc}$ ) pré-definidos, conforme exemplo da figura 16.

Figura 16 - Exemplo de segmentação de um sinal EMG através da técnica de janelamento



Fonte: Elaborado pelo autor (2021).

Scheme e Englehart (2011) afirmam que grandes janelas aumentam estabilidade e a eficácia da classificação, mas requerem maior tempo ( $T_d$ ) para decisão do classificador. Ainda sobre o tempo de janela e processamento, Englehart e Hudgins (2003) informam que, para não ocorrer problemas na execução dos movimentos de próteses que utilizam sensores EMG, é necessário que cada decisão do classificador seja menor que 300 ms.

Após a etapa de segmentação, para o sucesso de alguns classificadores, é necessária a extração de características dos sinais EMG que são então aplicadas para treinar um modelo de classificador. Diferentes técnicas têm sido utilizadas para a extração de características/recursos. Há três grupos principais de características: análises no domínio do tempo (TD - *Time Domain*), no domínio da frequência (FD - *Frequency Domain*) e no domínio de tempo-frequência (TFD - *Time-Frequency Domain*). Dentre as características extraídas utilizadas em diversas pesquisas podemos citar: Média do Valor Absoluto (MAV - *Mean Absolute Value*), Raiz Quadrática média (RMS - *Root Mean Square*), Comprimento da forma de onda (WL - *Wave Length*), Coeficientes de auto-regressão (AR - *Auto-Regressive*), Cruzamentos por zero (ZC - *Zero Crossing*), Frequência Média (MNF - *Mean Frequency*) e Transformada *Wavelet Packet* (WPT - *Wavelet Packet Transform*) (NAZMI *et al*, 2016). Vários métodos podem ser implementados para a classificação de sinais EMG, tais como Redes Neurais multicamadas, Máquinas de Vetores de Suporte (SVM - *Support Vector Machine*), k-vizinhos mais próximos (kNN - *k Nearest Neighbor*) e Regressão Linear (ALPAYDIN, 2010), (GINI *et al.*, 2012).

O próximo capítulo apresenta os conceitos básicos de aprendizado de máquina e as arquiteturas de classificadores para o reconhecimento de gestos de mão a partir do processamento de sinais EMG.

### 3 APRENDIZADO DE MÁQUINA

O aprendizado de máquina (em inglês, ML - *Machine Learning*) é um ramo da inteligência artificial cujo objetivo é a construção de sistemas que sejam capazes de gerar modelos de forma automatizada, a partir de exemplos fornecidos pelo usuário (aprendizado supervisionado) ou a partir de análise de características dos dados (aprendizado não supervisionado) (ALPAYDIN, 2010). Muitos tipos de tarefas podem ser resolvidos com aprendizado de máquina, as mais comuns incluem classificação (por exemplo, reconhecimento de padrões e processamento de som e fala), previsão (por exemplo, tendências de mercado, previsão meteorológica), sistemas de controle (por exemplo, controles adaptativos e robótica) (ALPAYDIN, 2010).

Uma das características da ML é a sua capacidade de generalização, ou seja, depois que um modelo é treinado com a ML, além de ter boa capacidade para identificar a classe que pertence cada instância, também deve ser capaz de classificar corretamente o conjunto de dados ainda não vistos anteriormente, pois é improvável que durante os testes os mesmos exemplos apareçam. Quando o modelo possui baixa capacidade de generalização, isto é, acaba decorando os dados de treinamento não conseguindo boas taxas de classificação para novas instâncias, diz-se que ele sofreu um superajustamento (*overfitting*) aos dados de treinamento.

Diversos métodos podem ser implementados para a classificação de sinais EMG, tais como RNAs multicamadas, Máquinas de Vetores de Suporte (SVM - *Support Vector Machine*), k-vizinhos mais próximos (kNN - *k Nearest Neighbor*), Análise de Discriminantes Lineares (LDA) e *Random Forests* (ATZORI *et al.*, 2016), (GINI *et al.*, 2012). Nesta tese os modelos de aprendizagem que serão explorados como possibilidade para a implementação do sistema de classificação de sinais EMG (RNA de múltiplas camadas, redes neurais recorrentes e redes neurais convolucionais) são descritos a seguir.

### 3.1 REDES NEURAIS ARTIFICIAIS


As Redes Neurais Artificiais (RNAs) implementam aspectos do aprendizado de máquina inspirados nas estruturas e funções de redes neurais biológicas. Os primeiros trabalhos foram apresentados por Warren McCulloch e Walter Pitts (1943) demonstrando que as Redes Neurais Artificiais podiam calcular funções aritméticas ou lógicas. Depois o trabalho de Frank Rosenblatt (1957) com a invenção do *perceptron* e seu método de aprendizagem. As redes neurais são comumente utilizadas para resolver problemas de regressão e classificação, podendo também serem utilizadas em vários tipos de problemas de aprendizado de máquina.

#### 3.1.1 Modelo de um neurônio

A representação gráfica de um neurônio artificial é apresentada na figura 17 composto dos seguintes elementos:

- Sinais de entrada ( $x_1, x_2, \dots, x_m$ );
- Conjunto de pesos ( $w_{k1}, w_{k2}, \dots, w_{km}$ );
- Somatório ( $\Sigma$ );
- Função de ativação [ $\varphi(\cdot)$ ];
- Saída ( $Y$ ).

Figura 17 - Modelo de um neurônio artificial



Fonte: Adaptado de Haykin (2011).

O neurônio possui várias entradas ( $x_1, x_2, \dots, x_m$ ) que podem ser estímulos externos ou saídas de outros neurônios. Estas entradas mencionadas são multiplicadas por pesos ( $W_{k1}, W_{k2}, \dots, W_{km}$ ) que são modificados durante o processo de aprendizagem. A ideia básica é que, quando o peso é pequeno, esta entrada em particular não tem grande influência no resultado da saída do neurônio. Caso contrário, grandes pesos sinápticos podem provocar uma grande alteração do resultado final. Após, todas estas entradas ponderadas são somadas (através de uma função de agregação) e enviadas para a função de ativação, que define o resultado da saída  $y_k$  do neurônio. Matematicamente, o neurônio artificial pode ser expresso da seguinte forma:

$$y_k = \varphi \left( \sum_{i=1}^m x_i W_{ki} + b_k \right), \quad (1)$$

onde  $x_i$  são os sinais de entrada da RNA,  $W_{ki}$  são os pesos sinápticos do neurônio,  $b_k$  é o viés ou bias,  $\varphi (\cdot)$  é a função de ativação e  $y_k$  é o sinal da saída do neurônio.

### 3.1.2 Função de Ativação

A função de ativação limita o intervalo permissível de amplitude do sinal de saída ( $y_k$ ) a um valor finito. Tipicamente este intervalo da saída do neurônio é normalizado em um intervalo fechado  $[0,1]$  ou alternativamente  $[-1,1]$  (HAYKIN, 2011). Entre as funções de ativação mais utilizadas, são apresentadas a função de limiar, a função sigmoide e a função linear retificada.


#### 3.1.2.1 Função Limiar

Também denominada de função degrau ou ainda como função de Heaviside, esta função define que a saída do neurônio é igual a zero, quando seu valor for negativo e 1, quando seu valor for positivo. Ela é descrita pela equação a seguir:

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (2)$$

O gráfico 1 apresenta a forma de onda desta função.

Gráfico 1 - Função limiar



Fonte: elaborado pelo autor (2021).


### 3.1.2.2 Função Sigmóide

Esta função é o tipo de função de ativação mais utilizada em redes neurais artificiais. É definida como uma função crescente, que possui um balanço entre o comportamento linear e não-linear (HAYKIN, 2011). Um exemplo de função sigmóide é a função logística definida pela equação (3):

$$\varphi(v) = \frac{1}{1 + e^{-av}}, \quad (3)$$

onde  $a$  é o parâmetro de inclinação da função. O gráfico 2 mostra a representação gráfica desta função.

Gráfico 2 - Função sigmóide

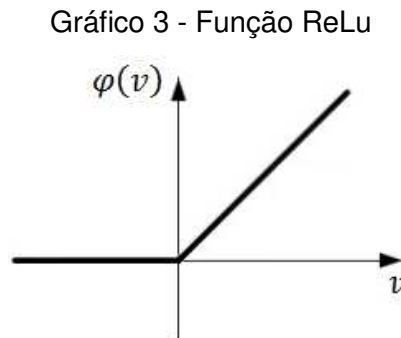


Fonte: elaborado pelo autor (2021).

Nesta função, a saída do neurônio assumirá valores entre 0 e 1.

### 3.1.2.3 Função ReLu (*Rectified Linear Unit* ou Unidade linear retificada)

A função retificadora linear, mostrada no gráfico 3, é uma das funções de ativação mais utilizadas atualmente em Redes Neurais Convolucionais (CNN) por ter uma eficiência próxima de funções mais complexas, mas com menor custo computacional acelerando o processo de treinamento. (KARPATHY, 2017).



Fonte: elaborado pelo autor (2021).

Sua função é definida matematicamente pela equação por  $\varphi(v) = \max(0, v)$  (KARPATHY, 2017).

### 3.1.3 Camada *Softmax*

A camada transforma cada saída para valores no intervalo de [0, 1] de tal forma que a soma de todas as saídas é igual a 1. Como resultado, o vetor de saída da camada *Softmax* pode ser considerado uma distribuição probabilística (BISHOP, 2006). Para seu cálculo, utiliza-se a equação (4):

$$f(X)_i = \frac{e^{X(i)}}{\sum_{j=1}^k e^{X(j)}}, \quad (4)$$


onde  $k$  é o número de elementos (classes) em  $X$ .

Esta camada é um importante recurso utilizado em redes de classificação multiclasse e deve ter o mesmo número de saídas que as classes.

### 3.1.4 Redes de camadas múltiplas

As redes do tipo MLP (*Multilayer Perceptron*), são arquiteturas de RNAs que apresentam além das camadas de entrada e saída, uma ou mais camadas ocultas, cujos nós são chamados também de neurônios ocultos. Estas camadas ocultas são capazes de proporcionar maior poder computacional para extrair características complexas do ambiente na busca pela resolução de problemas não linearmente separáveis (HAYKIN, 2011). A figura 18 ilustra a arquitetura de uma rede do tipo MLP totalmente conectada onde cada neurônio de uma camada é conectado a todos os neurônios da camada seguinte. Já em uma MLP parcialmente conectada, alguns neurônios não estão conectados entre todas as camadas.

Figura 18 - Arquitetura *Feedforward* com múltiplas camadas



Fonte: Adaptado de Silva *et al.* (2010).

Para o treinamento das redes MLP existem vários algoritmos de aprendizado, onde sua maioria envolve um procedimento iterativo para minimizar uma função erro  $E$  (custo ou objetivo), com ajustes nos pesos e bias da RNA (BISHOP, 2006). Entre os algoritmos, o mais conhecido é o de retropropagação de erro (*backpropagation*), podendo ser aplicado em redes neurais com funções de ativação diferenciáveis e com aprendizado supervisionado. A arquitetura MLP com uso do algoritmo *backpropagation* tem sido utilizada com muito sucesso na resolução de diversos problemas complexos (HAYKIN, 2011).



O algoritmo possui duas etapas: na primeira etapa, chamada de *forward* (propagação adiante), dados de entrada (padrões) são apresentados à rede e seu efeito é propagado, camada a camada, produzindo um conjunto de saídas como respostas reais da rede. Nesta primeira fase, os pesos sinápticos e bias permanecem inalterados. A segunda etapa, conhecida como *backward* ou propagação reversa, os pesos sinápticos e bias da última camada são recalculados, de acordo com uma regra de correção de erro, após são ajustados os pesos e bias da camada anterior até atingir a camada de entrada da RNA. Este processo se repete até que algum critério de parada seja satisfeito (SILVA *et al.*, 2010).

Existem vários métodos para a atualização dos pesos, chamados de otimizadores, dentre eles o Gradiente Descendente (GD - *Gradient Descent*) onde as equações de atualização dos pesos e bias são apresentadas respectivamente nas equações (5) e (6):

$$w^{(t+1)} = w^{(t)} - \eta \frac{\partial E}{\partial w^{(t)}} \quad (5)$$

$$b^{(t+1)} = b^{(t)} - \eta \frac{\partial E}{\partial b^{(t)}} \quad (6)$$


onde  $\eta$  é a taxa de aprendizado (*learning rate*).

Os pesos  $w$  e bias  $b$  são atualizados pelo negativo do gradiente da função custo  $E$  em relação aos pesos (ou bias). Outros otimizadores podem ser utilizados como o Gradiente Descendente Estocástico (SGD - *Stochastic Gradient Descent*), o *Adaptive Moment Estimation* (Adam) e o *SGD with Momentum* (GOODFELLOW *et al.*, 2016).

### 3.1.5 Redes Neurais Recorrentes

Diferentemente das redes neurais *feedforward*, as redes recorrentes (RNN - *Recurrent Neural Network*) são caracterizadas por possuírem neurônios cujas saídas realimentam a si próprios e/ou a outros neurônios de maneira a formar ciclos. Nesta arquitetura, mostrada na figura 19, por incluir loops, permite que ele tenha memória e explore a capacidade de armazenamento de informações temporais e sinais sequenciais.

Figura 19 - Arquitetura de uma rede neural recorrente

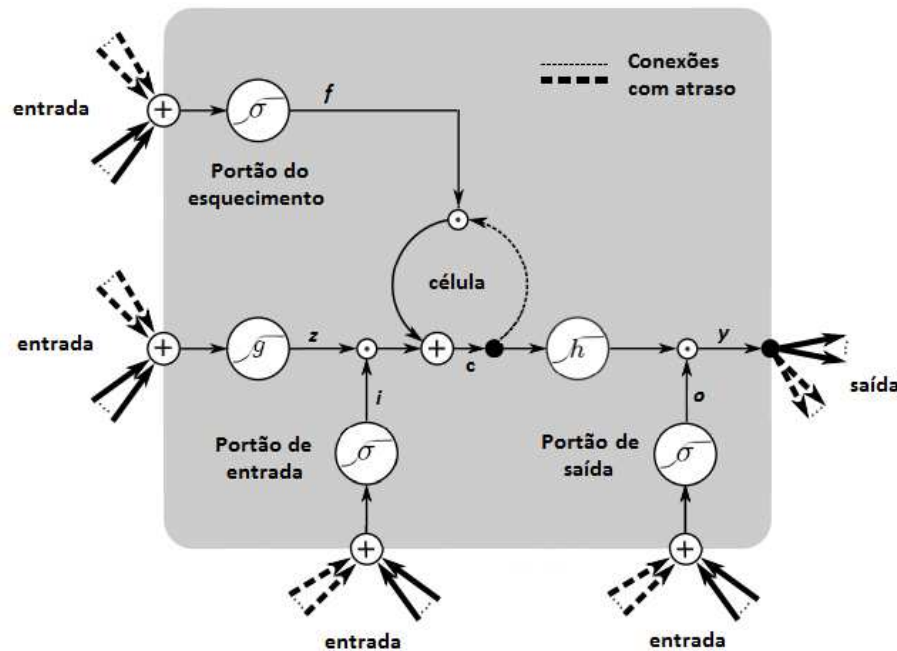


Fonte: Adaptado de Silva *et al.* (2010).

Um problema enfrentado pelas redes neurais recorrentes é o chamado desaparecimento do gradiente (*vanishing gradient*) onde redes com muitas camadas perdem a informação do gradiente. Uma solução proposta foi a inserção de uma memória à RNN para manter seu status durante vários passos de tempo. Esta estrutura é a Rede de Memória Longa de Curto Prazo (LSTM - *Long Short-Term Memory*) desenvolvida por Hochreiter e Schmidhuber (1997) e aprimorada por Gers *et al.* (2000) com a inclusão do portão do esquecimento. Outras variantes de arquiteturas LSTM têm sido sugeridas e implementadas.

Uma arquitetura de LSTM é apresentada na figura 20. Ela consiste em três portas (entrada, esquecimento e saída), entrada de bloco, funções de ativação, pesos, uma célula única e a saída do bloco que é conectada repetidamente de volta à entrada do bloco e a todos os portões (GREFF *et al.*, 2017).

Figura 20 - Esquemático de uma rede LSTM



Fonte: Adaptado de Greff *et al.* (2017).

O estado de entrada é a combinação do estado oculto e a entrada atual. O portão de entrada (*input gate*) decide se o estado da entrada alcança o estado interno. O portão de esquecimento (*forget gate*) decide se o estado interno considera ou não o estado anterior. O portão de saída (*output gate*) decide se o estado interno passa seu valor à saída e ao estado oculto do passo seguinte. As fórmulas vetoriais são mostradas nas equações (7) a (12):

$$z^t = \sigma(W^{zx} x^t + R^{zy} y^{(t-1)} + b_z) \quad (\text{entrada}) \quad (7)$$

$$i^t = \sigma(W^{ix} x^t + R^{iy} y^{(t-1)} + b_i) \quad (\text{porta de entrada}) \quad (8)$$

$$f^t = \sigma(W^{fx} x^t + R^{fy} y^{(t-1)} + b_f) \quad (\text{porta de esquecimento}) \quad (9)$$

$$c^t = i^t \odot z^t + f^t \odot c^{t-1} \quad (\text{estado da célula}) \quad (10)$$

$$o^t = \sigma(W^{ox} x^t + R^{oy} y^{(t-1)} + b_o) \quad (\text{porta de saída}) \quad (11)$$

$$y^t = o^t \odot c^t \quad (\text{saída}) \quad (12)$$

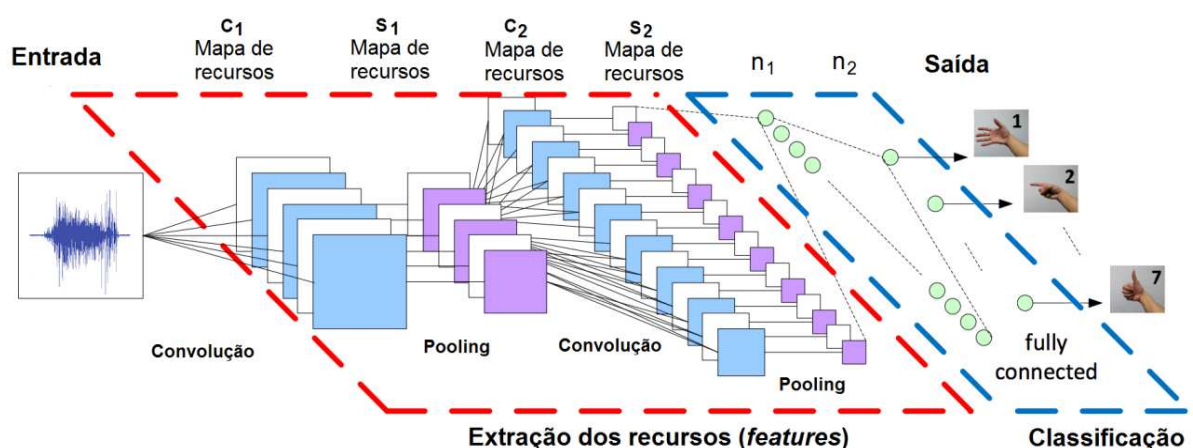
onde  $x$  é a entrada,  $W$ ,  $R$  e  $b$  são os pesos,  $y$  é a saída e  $\sigma$ ,  $g$  e  $h$  são as funções de ativação (as funções de ativação das portas são sigmóides e as demais são tangentes hiperbólicas).

### 3.1.6 Redes Neurais Convolucionais

Uma das categorias de *Machine Learning* é a Aprendizagem Profunda (*Deep Learning - DL*) sendo atualmente o estado da arte para a resolução de problemas via ML, em particular problemas de classificação. A principal diferença entre DL e ML é a forma de extração dos recursos/características relevantes para a classificação. Enquanto na ML exige que um cientista de dados determine manualmente quais são as características pertinentes, na DL o método de extração é realizado de forma automática.

Uma das arquiteturas mais utilizadas em DL é a Rede Neural Convolutiva (CNN). É um tipo especial de Rede Neural *Perceptron* de multicamadas utilizada com muito sucesso em aplicações de processamento de imagens e linguagem natural. A estrutura de uma CNN é composta tipicamente de 3 tipos de camadas: Convolutiva, *Pooling* (agrupamento) e *Fully Connected* (totalmente conectada) estruturadas em duas partes. A primeira parte, chamada de *feature extraction*, possui combinações de camadas convolucionais com camadas de *pooling*. A segunda parte, chamada de classificação, utiliza a camada totalmente conectada. Uma amostra de uma rede neural convolutiva é apresentada na figura 21.

Figura 21 - Arquitetura de uma rede neural convolutiva



Fonte: Adaptado de Peemen *et al.* (2011).

A camada convolutiva é o principal elemento que caracteriza uma CNN pois é a responsável por extrair as características do volume de dados. As camadas convolucionais consistem em diversos filtros (chamados de elementos estruturantes


ou *kernel*) que realizam a operação de convolução, gerando o chamado de mapa de características ou mapa de recursos. A convolução é definida pela equação (13) (GONZALEZ e WOODS, 2010):

$$w(x,y) * f(x,y) = \sum_{s=-a}^a \sum_{t=-b}^b w(s,t)f(x-s,y-t) , \quad (13)$$

onde  $f(x,y)$  é a imagem,  $w(x,y)$  é o elemento estruturante e  $a$  e  $b$  são as dimensões do elemento estruturante.

A figura 22 apresenta um exemplo de convolução entre uma imagem 4x3 e um kernel 2x2 que percorre a imagem de entrada em um processo de janelas móveis gerando na saída um mapa de características 3x2.

Figura 22 - Operação de convolução para uma entrada 2D




Fonte: Adaptado de Goodfellow *et al.* (2016).

Na construção de uma CNN, algumas características, denominados de hiperparâmetros, precisam ser ajustadas, por exemplo, o tamanho dos filtros, o número de filtros e o passo de deslizamento (*stride*) dos *kernels*. Nos filtros, o tamanho da máscara e os valores dos seus coeficientes definem o tipo de filtragem realizada. Os tipos de filtros mais comuns são os lineares de tamanho fixo que conseguem eliminar frequências indesejadas de um sinal de entrada ou realizar a função de um filtro passa-faixa.

A camada de *pooling*, inserida sempre após a camada convolucional, tem o objetivo de reduzir o tamanho espacial da representação de forma a minimizar o custo computacional e evitar o efeito *overfitting* (KARPATHY, 2017). Seu princípio se baseia na divisão da entrada em um conjunto de regiões retangulares não sobrepostas e estas unidades internas de cada elemento são utilizadas para criar uma nova unidade de saída. A função mais comumente utilizada em modelos CNN é a *max-pooling*, que consiste em selecionar o valor máximo entre as unidades de dentro de cada elemento. Na figura 23 temos um exemplo da operação *max-pooling* com elemento estruturante de dimensão 2x2 sobre uma imagem de entrada de 4x4 *pixels*. Existem outras funções de *pooling* como a média, a mediana e a norma L2.


Figura 23 - Função *max-pooling*



Fonte: elaborado pelo autor (2021).

Após o processo de *feature extraction* temos, pelos menos, uma camada chamada *Fully Connected (FC)*. Nesta camada todos os neurônios da camada anterior estão conectados com cada neurônio da camada seguinte (KARPATHY, 2017). Esta camada funciona de forma idêntica as camadas ocultas de uma rede neural padrão, onde cada neurônio possui um peso associado a cada elemento do vetor de entrada e é responsável por computar o resultado da classificação.

Devido a esta grande quantidade de neurônios nas camadas ocultas, a rede neural pode apresentar *overfitting*. Para minimizar este problema, uma técnica chamada *Dropout* é utilizada durante a fase de treinamento da rede (SRIVASTAVA *et al.*, 2014). Este processo consiste em remover, de forma randômica, alguns neurônios e suas conexões das camadas ocultas. O efeito da aplicação desta técnica em uma RNA é mostrado na figura 24.

Figura 24 - Técnica *Dropout*

Fonte: adaptado de Srivastava *et al.* (2014).

Na figura anterior à esquerda é apresentada a configuração de uma rede totalmente conectada, e à direita o resultado da aplicação com o desligamento de alguns neurônios. O *Dropout* introduz um hiperparâmetro na CNN, chamado de taxa  $p$ , que corresponde à probabilidade de manter o neurônio na rede. Este hiperparâmetro controla a intensidade do *dropout*. Segundo Srivastava *et al.* (2014), valores típicos de  $p$  para as camadas ocultas variam entre 0,5 e 0,8. Ainda informam que valores de  $p$  muito pequenos retardam o treinamento da rede e que valores muito altos de  $p$  podem não evitar o *overfitting*.

### 3.1.7 Floresta Aleatória


Para entender o funcionamento do algoritmo Floresta Aleatória (RF - *Random Forest*), precisamos compreender o funcionamento da árvore de decisão. A árvore de decisão é um tipo de algoritmo de aprendizagem supervisionada importante na realização de tarefas de regressão e classificação (CART - *Classification and Regression Trees*).

O algoritmo CART funciona tanto para variáveis categóricas quanto contínuas. Normalmente, as árvores de decisão, a partir do conjunto de dados de treinamento, rótulos (*labels*) e *features*, elaboram um conjunto de regras utilizando cálculos do índice de Gini ou do ganho de informação. Este processo de construção da árvore de decisão para grandes conjuntos de dados pode requerer um elevado custo computacional, contudo, após a construção do modelo as classificações são muito rápidas. Estas árvores muito profundas podem apresentar problemas de

*overfitting* (sobreajuste) e uma forma de reduzir esta questão é a utilização do método de poda da árvore (BREIMAN *et al.*, 1984) que remove seções da árvore que não são críticas e/ou redundantes na classificação.

Já o algoritmo Floresta Aleatória, proposto pela primeira vez por BREIMAN (2001) combina árvores de decisão sem poda e *Bagging*. Duas aleatoriedades são consideradas: amostragem aleatória do conjunto de dados de treinamento ao construir árvores (chamado de *Bootstrap*) (BREIMAN, 1996) e subconjuntos aleatórios de *features* (*Randomizing*) ao dividir os nós (BREIMAN, 2001). A partir de tais subconjuntos é realizada a predição para cada árvore criada na primeira fase, evitando desta forma o sobreajuste. No final, a resposta do sistema é a classe que obteve o maior número de votos dos vários classificadores. A RF pode ser ilustrada no esquema da figura 25 e explicada pelo pseudocódigo a seguir:

Figura 25 - Esquema do processo de classificação de uma Floresta Aleatória



Fonte: elaborado pelo autor (2021).



1. Selecione aleatoriamente  $m$  *features* do total de  $M$  *features*, onde  $m \ll M$ ;
2. Utilize a melhor divisão entre as características  $m$  para dividir o nó.
3. Repita as etapas 1 e 2 até que o número de  $f$  nós seja alcançado;
4. Construa  $n$  árvores repetindo as etapas de 1 a 3;
5. Construa os classificadores da floresta aleatória;
6. Para novos dados, utilize as regras de cada árvore criada e encontre a predição de cada árvore;
7. Calcule os votos e considere a classe com maior votação como resultado da Floresta Aleatória.

A alteração dos hiperparâmetros da Floresta Aleatória pode aumentar o poder de predição do modelo ou torná-lo mais rápido. Desta forma, três parâmetros são destacados: número de estimadores ( $n\_estimators$ ), número máximo de *features* ( $max\_features$ ) e a profundidade máxima ( $max\_depth$ ). O número de estimadores informa o número de árvores a serem construídas antes do processo de votação. Em geral, uma quantidade elevada de árvores aumenta o desempenho do classificador, mas também torna o processamento mais lento. O número máximo de *features* informa o número de características a serem utilizadas na construção de uma árvore. Já profundidade máxima da árvore é o número máximo de níveis que uma árvore pode crescer. Este algoritmo é difundido em várias áreas e é constantemente aplicado em sistemas de reconhecimento de gestos a partir de sinais EMG, como apresentados por Zhou *et al.* (2019), Robinson *et al.* (2017) e Atzori *et al.* (2016).

### 3.2 REDUÇÃO DE DIMENSIONALIDADE

A redução de dimensionalidade (ou redução de dimensão) transforma vetores de dados de um espaço de alta dimensão em um espaço de baixa dimensão. Técnicas como Análise de Componentes Principais (PCA - *Principal Component Analysis*) e Análise de Discriminantes Lineares (LDA - *Linear Discriminant Analysis*) são utilizadas na etapa de pré-processamento para aplicações de classificação de padrões (RAURALE *et al.*, 2020). Na projeção linear, o PCA maximiza a variância

dos dados, enquanto o LDA maximiza a separação entre várias classes e minimiza a distância dentro das classes simultaneamente (RAURALE *et al.*, 2020 e THARWAT *et al.*, 2017). As técnicas são descritas nas seguintes etapas:

- 1) Calcular o vetor de recurso médio  $\bar{f}$  para as diferentes classes do conjunto de dados;
- 2) Calcular a matriz de dispersão dentro da classe e a matriz de dispersão entre as classes (matriz de covariância no caso em que a técnica PCA é usada);
- 3) Selecionar  $k$  autovetores que correspondem aos  $k$  maiores autovalores;
- 4) Construir a matriz de projeção  $L$  ( $P$  no caso em que a técnica PCA é usada) usando maiores  $k$  autovetores;
- 5) Usar a matriz  $L$  (ou  $P$ ) para transformar as amostras de dimensão  $d$  no novo subespaço de dimensão  $k$ . Isso pode ser resumido pela equação 14:

$$Y_{n \times k} = X_{n \times d} L_{d \times k} , \quad (14)$$

onde uma amostra  $X \in \mathbb{R}^{n \times d}$  ( $n$  e  $d$  são o número de amostras e a dimensão do conjunto de dados, respectivamente) pode ser projetada na matriz de transformação linear  $L \in \mathbb{R}^{d \times k}$  ( $P \in \mathbb{R}^{d \times k}$  no caso em que a técnica PCA é usada) para obter uma nova amostra  $Y \in \mathbb{R}^{n \times k}$  (onde  $k \ll d$ ). A LDA é a técnica de redução de dimensionalidade mais comumente usada em sistemas de classificação EMG (RAURALE *et al.*, 2020).

Após esta revisão bibliográfica focada em três tópicos (próteses, eletromiografia e inteligência artificial), no próximo capítulo são abordados os trabalhos relacionados que compreendem o estado da arte do objeto de pesquisa desta tese.

## 4 TRABALHOS RELACIONADOS

Este capítulo descreve os estudos da última década sobre classificação de padrões EMG. A pesquisa para sua localização foi realizada na base de periódicos da CAPES utilizando os termos associados EMG, sEMG, *Artificial Neural Networks*, *Random Forest*, *Support Vector Machines* e *Prosthesis*. Foram consultadas as principais revistas científicas (IEEE, PLoS ONE, Elsevier, Scientific Reports, Frontiers) e conferências na área, bem como agregadores de conteúdo científico. O objetivo principal deste estudo foi identificar as atuais tendências e desafios na área.

Através dos esforços de muitas iniciativas acadêmicas e comerciais, o reconhecimento de movimentos humanos usando sinais de eletromiografia de superfície tem sido fortemente estudado nesta última década. Diferentes métodos e recursos para reconhecimento de padrões EMG têm sido comparados no intuito de incorporar mais tecnologias nas próteses de membros. Nestes estudos verifica-se a preocupação em pelo menos um destes três pontos: a inserção de mais sinais elétricos (sensores de força, deslizamento e acelerômetros) para o aumento da acurácia, a utilização de próteses (*open source* ou comerciais) nas pesquisas para testes *online* e o aumento do número de movimentos a serem executados por estas próteses.

A tabela 2 apresenta um resumo de diferentes métodos utilizados para extração de características e classificação baseados em reconhecimento de padrões para o controle de próteses. Esta tabela foi composta com os seguintes itens de análise:

- a) Quantidade de eletrodos: permite identificar a qualidade do conjunto de dados usado na classificação;
- b) Outros sensores: possibilita avaliar como o conjunto de dados de treinamento foi formado e se houve inclusão de aspectos (informações) adicionais além da EMG;
- c) Prótese: utilização de modelos comerciais ou *open source* para avaliação *online*, na busca de testes mais reais (práticas clínicas);
- d) Método: analisa quais métodos foram escolhidos para a tarefa de classificação;

e) Pessoas: número de participantes dos experimentos descritos nos artigos. Alguns trabalhos possuem apenas voluntários não amputados e em outros, apresentam dos dois grupos (amputados e não amputados);

f) Ações treinadas: número de ações utilizadas nos experimentos para treino de reconhecimento de movimentos;

g) Resultados/Acurácia: apresenta os valores de acurácia na classificação dos movimentos e apresenta comparação entre os métodos analisados pelo artigo.

Os algoritmos mais utilizados nas pesquisas incluem SVM, kNN, Análise de Discriminantes Lineares (LDA - *Linear Discriminant Analysis*), MLP (*Multilayer Perceptron*), Redes Neurais Convolucionais (CNN - *Convolutional Neural Network*), Redes Neurais Recorrentes (RNN - *Recurrent Neural Network*), Floresta Aleatória (RF - *Random Forest*), mas alguns trabalhos apresentam outros métodos de classificação, entre eles as Redes de Crenças Profundas (DBN - *Deep Belief Network*), Análise Discriminante Quadrática (QDA - *Quadratic Discriminant Analysis*), Método Adaptativo baseado em *Kernels* (KRLS - *Kernel Recursive Least Squares*), Regressão Logística (SLR - *Simple Logistic Regression*), *Autoencoders* (AE), *Extreme Learning Machines* (ELM), Cálculo de Similaridade (CoS - *Cosine Similarity*), Árvores de Decisão (DT - *Decision Tree* e LMT - *Logistic Model Tree*), EAM - *Extended Associated Memories* e Estimativa da Máxima Verossimilhança (MLE - *Maximum Likelihood Estimation*).

Tabela 2 - Comparação de pesquisas de controle de próteses

Autor(es)	Quantidade de eletrodos EMG	Outros sensores	Prótese	Método(s)	Número de voluntários	Ações treinadas	Resultados Acurácia (%)
Abbaspour <i>et al.</i> (2020)	4	-	-	MLE, LDA, kNN, SVM, DT, MLP	20 N	11	Melhor: MLE (97,43) MLE > LDA > kNN > MLP > SVM > DT
Raurale <i>et al.</i> (2020)	8	-	-	MLP, SVM, kNN	10 N	9	Melhor: MLP (99,30) MLP > SVM > kNN
Sánchez-Velasco <i>et al.</i> (2020)	8	-	<i>Open source</i>	EAM	1 N	8	95,83
Cotê-Allard <i>et al.</i> (2019)	8	-	-	CNN	10 N 17 N	18 7	CNN (68,98) CNN (98,31)
Zhang <i>et al.</i> (2019)	8	-	-	MLP	12 N	5 ( <i>online</i> )	98,70
Sattar <i>et al.</i> (2019)	8	-	Braço com 2 DOF	MLP, SVM	10 N	5	MLP: 94,00 ( <i>offline</i> ) SVM: 85,00 ( <i>online</i> )
Kim <i>et al.</i> (2019)	12	-	-	CNN	40 N + 11 A	50	Amputados: 36,00 Não amputados: 61,00
Zhou <i>et al.</i> (2019)	12	-	-	RF	10 N	12	84,11
Atzori e Müller (2019)	12	-	-	RF	10 N + 10 A	41	~77,00 (N) ~ 56,00 (A)
Cene <i>et al.</i> (2018)	12	-	-	ELM	4 N	7	94,04
Ameri <i>et al.</i> (2018)	8	-	-	CNN, SVM	17 N	8	CNN (91,61) > SVM (90,63)

Fonte: elaborado pelo autor (2021).

Tabela 2 - Comparação de pesquisas de controle de próteses (cont.)

Autor(es)	Quantidade de eletrodos EMG	Outros sensores	Prótese	Método(s)	Número de voluntários	Ações treinadas	Resultados Acurácia (%)
Ding <i>et al.</i> (2018)	12	-	-	CNN	40 N	50	78,86
Geng <i>et al.</i> (2018)	12	-	-	CNN	40 N	50	77,80
Motoche e Benalcázar (2018)	8	-	-	MLP	10 N	6	90,70
Laezza (2018)	8	-	-	RNN, RNN + CNN, CNN	20 N + 2 A	30	Melhor: RNN (89,42) RNN > RNN + CNN > CNN
Patel <i>et al.</i> (2018)	8	-	Michelangelo	CoS, LDA	7 N ( <i>offline</i> ) 11 N + 1 A ( <i>online</i> )	8 ( <i>offline</i> ) 4 ( <i>online</i> )	LDA (89,20) > CoS (82,50)
Rehman <i>et al.</i> (2017)	6	-	-	AE, LDA	5 N 2 A	11	AE: 98,90 (N) e 98,40 (A) LDA: 96,26 (N) e 94,27 (A)
Krasoulis <i>et al.</i> (2017)	12	UMI	-	LDA	40 N + 2 A	40	82,70 (N) e 77,80 (A)
Benatti <i>et al.</i> (2017)	4	-	i-Limb	SVM	5 N + 4 A	3	87,37 (N) e 89,09 (A)
Côté-Allard <i>et al.</i> (2017)	8	UMI	Jaco (braço robótico)	CNN	18 N	7	97,81
Robinson <i>et al.</i> (2017)	12	-	-	kNN, MLP, RF, SVM	11 N	17	Melhor: RF (88,94) RF > kNN > SVM > MLP
Atzori <i>et al.</i> (2016)	12	-	-	CNN, kNN, RF, SVM, LDA	67 N + 11 A	50	Amputados: SVM (46,27) SVM > RF > CNN > kNN > LDA Não amputados: RF (75,27) RF > SVM > kNN > CNN > LDA

Fonte: elaborado pelo autor (2021).

Tabela 2 - Comparação de pesquisas de controle de próteses (cont.)

Autor(es)	Quantidade de eletrodos EMG	Outros sensores	Prótese	Método(s)	Número de voluntários	Ações treinadas	Resultados Acurácia (%)
Veer e Sharma (2016)	2	-	-	MLP	5 N	4	92,50
Shim e Lee (2015)	2	-	-	DBN, LDA, SVM	28 N	5	Melhor: DBM (88,60) DBM > SVM > LDA KRSL: 77,00 (EMG) (Não amputados)
Atzori <i>et al.</i> (2014b)	12	ACC	-	KRLS, LDA e kNN	40 N + 5 A	40	KRSL: 61,14 (EMG) (Amputados) KRSL: ~ 80,00 (EMG + ACC) (Amputados) Melhor: SLR (93,00)
Geethanjali e Ray (2014)	4	-	<i>Open source</i>	SLR, DT, LMT, MLP, LDA e SVM	10 N + 2 A	6	SLR > MLP > LDA > LMT > SVM > DT
Nazemi e Maleki (2014)	10	-	-	MLP, LDA, SVM	27 N	52	MLP (96,34) > SVM (85,19) > LDA (84,23)
Al-Timemy <i>et al.</i> (2013)	6	-	-	LDA	10 N + 6 A	15 (N) 12 (A)	98,25 (N) 90,57 (A)
Young <i>et al.</i> (2013)	6	-	-	LDA	6 N + 2 A	6	93,40 (N) e 90,6 (A)
Phinyomark <i>et al.</i> (2013)	4	-	-	RF, LDA, MLP, kNN e QDA	1 N	11	Melhor: LDA (98,87) LDA > RF > kNN > QDA > MLP
Ibrahimi <i>et al.</i> (2013)	2	-	-	MLP	3 N	4	88,40

Nota: A (amputado); N (não amputado); ACC (acelerômetro); UMI (Unidade de Medição Inercial)

Fonte: elaborado pelo autor (2021).

A seguir são apresentados maiores detalhes sobre os trabalhos descritos na tabela e sumarizados os pontos que representam tendência e desafios.

Sánchez-Velasco *et al.* (2020) apresentaram o uso de um bracelete comercial de aquisição de sinais EMG para controlar uma prótese de mão de código aberto com seis graus de liberdade. O experimento utilizou dois dispositivos portáteis de *hardware* comercial para o processamento e acionamento da prótese. Neste estudo, para a operação do classificador *Extended Associated Memories* (EAM), a função Média do Valor Absoluto (MAV - *Median Absolute Value*) foi utilizada para extrair as *features*. O sistema foi testado em oito tarefas de reconhecimento de gestos de mão que apresentou taxas de acertos de 95,83%.

Zhou *et al.* (2019) propuseram e analisaram a classificação de 12 movimentos/gestos de mão através do banco de dados NinaPro DB4 (10 voluntários não amputados). Foram utilizadas diferentes combinações de *features* no domínio do tempo e o classificador RF. O melhor resultado foi encontrado para o conjunto de *features* RMS+WL+ZC com acurácia média de 84,11%

Sattar e colaboradores (2019) desenvolveram um controle de prótese de braço utilizando uma plataforma comercial para aquisição de sinais EMG e o sistema Raspberry para processar e controlar cinco movimentos/gestos de mão. O controle foi simulado e implementado usando o algoritmo de controle Proporcional-Integral-Derivativo (PID). O treinamento *Offline* apresentou melhor acurácia (94%) utilizando redes neurais artificiais. Para a análise em tempo real, o classificador executado que apresentou maior taxa de acerto foi o SVM com 85%.

Ameri *et al.* (2018) propuseram e testaram um classificador *real-time* utilizando CNN e SVM. Dezesete voluntários não amputados participaram do estudo e utilizaram 8 pares de eletrodos bipolares igualmente espaçados para a classificação de 8 movimentos (flexão, extensão, pronação, supinação e suas combinações: extensão e pronação, extensão e supinação, flexão e pronação e flexão e supinação), obtendo taxas de acertos de 91,61% para CNN e 90,63% para o classificador SVM.

Motoche e Benalcázar (2018) também apresentam o estudo de um classificador *real-time* e utilizaram o bracelete Myo para a aquisição de sinais EMG em 10 voluntários não amputados. Foram registrados a posição repouso e cinco movimentos diferentes (punho, dedos abertos, toque duplo, movimento para a



esquerda e movimento para a direita) e uma rede neural utilizada para sua classificação. A matriz de confusão apresentou uma acurácia de 90,7% (o melhor movimento classificado foi o de punho com 98,3% e o menor foi o toque duplo com 85,3%).

Laezza (2018) utilizou oito eletrodos de superfície na análise da classificação de 30 movimentos em 24 voluntários (20 sujeitos não amputados e 2 sujeitos amputados). Três diferentes arquiteturas de redes neurais foram testadas: RNN, CNN e arquitetura híbrida CNN + RNN. No experimento a RNN apresentou uma acurácia média de 91,81%, comparado com 89,01% para a CNN e 90,4% para o híbrido CNN-RNN.

Côté-Allard *et al.* (2017) analisaram um classificador *real-time* utilizando Redes Neurais Convolucionais. Dezesete voluntários não amputados participaram do estudo e utilizaram o bracelete Myo para a aquisição de sinais EMG e classificação de sete movimentos (mão fechada, mão aberta, flexão do punho, extensão do punho, desvio ulnar, desvio radial e descanso). O sistema foi aplicado no controle de um braço robótico de 6 DoF. Como resultado a rede apresentou uma acurácia de 97,81%.

Atzori *et al.* (2016) analisaram a classificação de 50 movimentos através do banco de dados NinaPro DB1, DB2 e DB3 (11 voluntários amputados e 67 voluntários não amputados). Foram utilizados 5 métodos: CNN, kNN, RF, SVM e LDA e extraídas características (*features*) através das funções WL, RMS, Transformada Discreta Marginal de Wavelet (mWDT), Histograma (HIST) e uma combinação normalizada de todas estas características juntas. O melhor classificador para sujeitos não amputados foi o RF com taxa de acerto de 75,27% (banco de dados NinaPro DB2) e para os sujeitos amputados foi a SVM com acurácia de 46,27%.

Geethanjali e Ray (2014) utilizaram 4 pares de eletrodos de superfície para avaliar o desempenho de várias técnicas de classificação diferentes: SLR (*Simple Logistic Regression*), DT (*Decision Tree*), LMT (*Logistic Model Tree*), MLP, LDA e SVM. Quatro métricas foram utilizadas: acurácia, tempo de processamento, uso de memória e robustez do modelo (classificação de dados EMG gravados com intervalos de 1 hora cada). Os resultados apontaram o SLR como melhor classificador. Após esta análise um sistema *real-time* de controle foi implementado em uma prótese *open source* utilizando SLR e testado para dois movimentos.

Atzori *et al.* (2014b) analisaram a classificação de 40 movimentos em 5 voluntários amputados e 40 voluntários não amputados, usando em ambos 12 eletrodos de superfície e, em cada eletrodo foi incorporado um acelerômetro de 3 eixos. Foram utilizados 3 métodos: KRLS, LDA e kNN. Utilizando apenas dados EMG, o melhor classificador foi o KRLS com taxa de acerto de 61,14% para os sujeitos amputados, 15,86% menos em comparação com os sujeitos não amputados. Para o sistema multimodal, o resultado para sujeitos amputados obteve uma acurácia média próxima de 80% também com o classificador KRLS.

Com relação aos trabalhos apresentados na tabela 2, observamos que grande parte dos estudos utiliza como classificadores métodos tradicionais como kNN, RF, SVM e Redes Neurais MLP e em menor quantidade outros métodos, chamados aqui de classificadores promissores, como EAM, Redes Neurais Convolucionais e Recorrentes. Pode-se verificar também que a maioria dos autores trataram a classificação dos movimentos de mão-braço através de sinais mioelétricos sem considerar uma etapa seguinte de acionamento de próteses de mão (comerciais ou *open source*), utilizando computadores *desktop* no processamento dos bancos de dados; poucos trabalhos propuseram a implantação dos classificadores em sistemas embarcados, plataformas portáteis com menores recursos de processamento e memória mas a custos relativamente menores em relação aos computadores *desktop*. Outro ponto de observação é que muitos dos movimentos selecionados e classificados nestes trabalhos ainda não podem ser realizados por tais próteses.


Diante destas observações considerou-se como ponto de contribuição da tese o desenvolvimento de um sistema embarcado capaz de realizar de forma *real time* a classificação de movimentos utilizando Aprendizado de Máquina a partir de sinais mioelétricos, sua implantação em um sistema embarcado (tornando o dispositivo portátil) e o acionamento elétrico de uma prótese de mão, integrando todos os elementos que compõem uma prótese de mão mioelétrica e levando em consideração também o aspecto custo em todas as etapas do protótipo (sistemas mecânico, elétrico, eletrônico e computacional). Para o êxito desta implementação foi necessário o desenvolvimento de um protocolo para a aquisição de sinais EMG e a criação de um banco de dados de voluntários locais, sendo estes dois pontos também contribuições do trabalho. E experimentos de prensão e deslocamentos de objetos foram realizados para validar a integração dos elementos do sistema. O próximo capítulo apresenta os detalhes da abordagem proposta para a execução deste trabalho.

## 5 MATERIAIS E MÉTODOS

Neste capítulo, são descritos os materiais e métodos selecionados para a implementação do sistema de reconhecimento automático de padrões de movimentos do segmento mão-braço através de do uso de técnicas de aprendizado de máquina aplicadas a sinais EMG.

Na figura 26 podem ser observados os diversos componentes implementados/utilizados nesta tese, tais como os componentes mecânicos (a prótese), elementos de *hardware* (sistema de aquisição de sinais, sensores EMG de superfície, *driver/interface* para acionamento elétrico da prótese), os elementos/componentes de *software* (pré-processamento, extração de *features*, classificadores), os sinais EMG a partir de movimentos/gestos de mão realizados e as bases de dados de sinais EMG. A dinâmica de funcionamento geral também é apresentada destacando dois ciclos principais denominados de "Sistema *Offline*" e de "Sistema *Online*".

Figura 26 - Diagrama de blocos das etapas para implementação da prótese de mão de baixo custo



Fonte: elaborado pelo autor (2021).

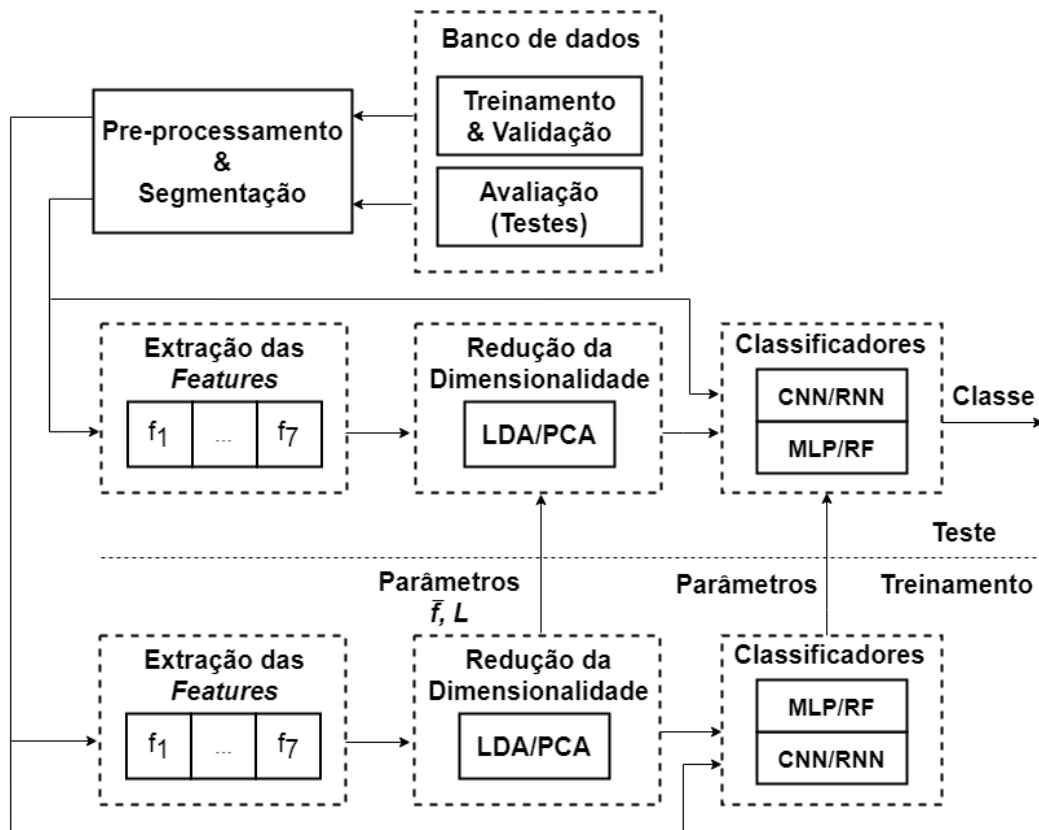
No sistema *Offline*, as etapas de treinamento e testes dos classificadores utilizaram três bancos de dados de sinais EMG: dois bancos de dados NinaPro (ATZORI *et al.*, 2014a; ATZORI *et al.*, 2015) e o banco de dados KidoPro (banco de dados coletado e disponibilizado nesta tese).

Uma vez treinados e comparados com a literatura existente, a arquitetura mais bem avaliada em termos de classificação e portabilidade (facilidade para salvar e carregar as configurações e parâmetros de um classificador) foi implantada em uma plataforma de prototipagem SoC de baixo custo, no caso a plataforma Raspberry Pi, iniciando assim o segundo ciclo chamado nesta tese de sistema *Online*. Recursos foram incorporados ao sistema, tais como: aquisição *real-time* dos sinais EMG e acionamento elétrico da prótese de mão. Uma descrição de dois experimentos foi realizada para validação do sistema protético. Estes componentes e estas dinâmicas dos sistemas *Offline* e *Online* são detalhados nos próximos subcapítulos.

## 5.1 SISTEMA OFFLINE

O sistema *offline*, ilustrado no diagrama de blocos da figura 27, promove o desenvolvimento de um modelo de reconhecimento de padrões de movimentos do segmento mão-braço através de sinais EMG. O sistema proposto é composto pelos seguintes elementos: bancos de dados de sinais eletromiográficos, componentes de pré-processamento e segmentação de sinais, extração de características (*features*), redução de dimensionalidade e classificação. De acordo com o tipo de classificador, alguns elementos não foram utilizados (como a extração de *features* e redução de dimensionalidade para os classificadores CNN e RNN).

Figura 27 - Diagrama de blocos do modelo *Offline* de reconhecimento de padrões



Fonte: elaborado pelo autor (2021).

Os elementos do sistema de reconhecimento de padrões de movimentos do segmento mão-braço através de sinais EMG foram implementados, treinados e testados primeiramente, em um computador *desktop* baseado em Windows de 64 bits com processador Intel Core-i5 2,5 GHz e 4 GB de memória RAM DDR3 1333 MHz, sendo este ciclo chamado de Sistema *Offline*. Todos os algoritmos foram desenvolvidos utilizando linguagem de programação Python versão 3.7.6 (PYTHON, 2019) em conjunto com a plataforma de ciência de dados Anaconda (ANACONDA, 2019) e o ambiente de desenvolvimento/programação Spyder versão 4.0.1. Para a implementação dos classificadores foram utilizadas as bibliotecas *Keras* (CHOLLET, 2018) e *Scikit-learn* (PEDREGOSA *et al.*, 2011). As bibliotecas Python para processamento numérico, análise de dados e plotagem de gráficos foram *Pandas* (MCKINNEY, 2019), *NumPy* (OLIPHANT, 2006), *Scipy* (JONES *et al.*, 2001) e *Matplotlib* (HUNTER, 2007).

O desenvolvimento do sistema *offline* foi dividido em duas etapas: A primeira etapa consiste em uma série de cinco ensaios para avaliação do desempenho das arquiteturas implementadas a partir da alteração e/ou incorporação de diferentes recursos aos classificadores. Para estes experimentos foram utilizados dois bancos de dados NinaPro. A segunda etapa descreve o processo para aquisição e geração de um novo banco de dados de sinais EMG a partir de movimentos de mão de voluntários locais e posteriormente sua classificação baseada nos gestos realizados. Estas duas etapas do sistema *offline* são descritas a seguir.

### 5.1.1 Experimentos com bancos de dados NinaPro

Cinco ensaios foram realizados para avaliar o desempenho dos classificadores mediante alteração de parâmetros e/ou inserção de recursos, tais como os efeitos da mudança no número de canais EMG, o uso simultâneo de sinais de acelerometria e eletromiografia para reconhecer os gestos corretos das mãos, alteração da janela de segmentação e redução da dimensionalidade. Estes ensaios estão resumidos no quadro 2.

Quadro 2 - Experimentos realizados

Ensaio	Descrição	Sensores
1	Classificadores e classes	EMG
2	Segmentação	EMG
3	Número de canais	EMG
4	Uso de acelerometria	EMG e ACC
5	Redução da dimensionalidade	EMG e ACC

Fonte: elaborado pelo autor (2021).

O primeiro ensaio avaliou o desempenho de quatro classificadores implementados nesta tese: dois considerados tradicionais, como as Redes Neurais multicamadas e Floresta Aleatória e dois métodos promissores: Redes Neurais Convolucionais e Redes Neurais Recorrentes. Os primeiros 10 voluntários do conjunto de dados DB2 e 10 voluntários do conjunto de dados DB3 foram usados. Consideramos ensaios com 12 e 50 gestos/movimentos de mão, incluindo a posição de repouso. Os dois melhores classificadores foram ainda comparados com a literatura existente e testados nos quatro ensaios seguintes do sistema *offline*.

O segundo ensaio avaliou o desempenho dos classificadores para diferentes tamanhos de segmentos e incrementos de janela. Diferentes configurações e combinações de tamanhos e incrementos de janela foram verificados na literatura existente variando o segmento de janela desde 128 ms até 1 s e incrementos (sobreposição) configurados desde 10 ms até 250 ms (PHINYOMARK *et al.*, 2013; MOTOICHE e BENALCÁZAR, 2018). Ao aumentar o segmento da janela, a acurácia dos modelos aumenta à medida que mais dados são coletados para o reconhecimento dos movimentos/gestos, mas a sua carga computacional também aumenta (PHINYOMARK *et al.*, 2013). Além disso, um limite de 300 ms para o segmento é necessário a fim de evitar problemas na execução dos movimentos de próteses que utilizam sensores EMG (ENGLEHART e HUDGINS, 2003). Três configurações de segmento/incremento de janela foram testadas: 100 ms/50 ms, 200 ms/100 ms e 250 ms/125 ms.

No terceiro experimento foi avaliado o efeito da mudança do número de canais EMG na classificação dos movimentos. Geralmente, a utilização de mais canais EMG fornece mais informações eletrofisiológicas do paciente, o que melhora o desempenho de classificação dos sistemas de reconhecimento de padrão. No entanto, isso provoca um incremento econômico (sistemas de aquisição maiores ou com mais módulos de aquisição) e também aumenta o custo do processamento de dados para os sistemas controlados por EMG (YAO *et al.*, 2020). Então, avaliar a redução do número de canais mantendo níveis aceitáveis de desempenho pode ser um aspecto interessante no projeto de sistemas de reconhecimento de padrão através de sinais EMG. Cinco conjuntos de eletrodos (número de canais variando de 4 a 12 eletrodos) foram testados e estão descritos na tabela 3. O ensaio foi realizado com 12 classes.

Tabela 3 - Ensaio para diferentes conjuntos de canais EMG

<b>Conjunto de canais EMG</b>	<b>Ao redor do braço</b>	<b>Bíceps e tríceps</b>	<b>Flexão e extensão dos dedos</b>	<b>Total de canais EMG</b>
A	-	2	2	4
B	2	2	2	6
C	4	2	2	8
D	8	2	-	10
E	8	2	2	12

Fonte: elaborado pelo autor (2021).

No experimento 4, combinamos os sinais de eletromiografia com os sinais de acelerometria em um classificador multimodal e investigamos o desempenho no reconhecimento de padrões. Esta integração pode permitir que novas configurações de sistemas de aquisição de sinais, considerando um menor número de canais EMG frente a inserção de sensores inerciais, consigam manter níveis aceitáveis de desempenho. Foram utilizados os 36 sinais de ACC (12 eletrodos x 3 eixos amostrados a 148 Hz) dos bancos de dados NinaPro DB2 e DB3 e a função Valor Médio Absoluto (MAV) foi empregada para calcular as *features* nesta modalidade, conforme proposto por Fougner *et al.* (2011).

Com a utilização de um grande número de canais EMG e ACC e sete *features* extraídas por canal EMG, nos deparamos com sistemas de classificação que apresentaram vetor de *features* de alta dimensão. Com o objetivo de reduzir o custo computacional e evitar *overfitting* na etapa de classificação um último ensaio, de redução da dimensionalidade, foi realizado para mapear o vetor de *features* para um espaço dimensional inferior. Duas técnicas foram empregadas: LDA e PCA. O ensaio foi realizado com 12 e 24 classes e a dimensionalidade ( $k$ ) do vetor de saída para o método LDA foi escolhida para ser o número de classes menos um (THARWAT *et al.*, 2017).

### **5.1.2 Desenvolvimento do banco de dados local**

Após a classificação e validação dos classificadores implementados, utilizando sinais EMG de dois bancos de dados de referência (NinaPro DB1 e DB2), foi realizado o ensaio para aquisição de sinais EMG de um grupo de voluntários locais com o objetivo de validar o *dataset*, realizar classificação dos gestos/movimentos de mão e testes de preensão a partir de um novo experimento (sistema *Online*). O quadro 3 apresenta um esboço das etapas/rotinas implementadas.



Quadro 3 - Etapas (rotinas) para criação do banco de dados de sinais EMG e classificação *offline*

- Inicializa o(s) dispositivo(s) de aquisição de sinais EMG
- Realiza a aquisição dos sinais EMG (dados brutos)
- Rotula os dados
  - Método TKEO
  - Formatação do arquivo
- Separa os dados (treinamento, validação e teste)
- Pré-processamento
  - Ajuste da escala dos sinais EMG
  - Filtragem
  - Retificação
  - Normalização
  - Segmentação
- Calcula as *features* no domínio do tempo
- Redução da dimensionalidade (LDA ou PCA)
- Treina o(s) classificador(es)
- Testa (*offline*) o(s) classificador(es)
- Salva as configurações e parâmetros do(s) classificador(es)

Fonte: elaborado pelo autor (2021).

A seguir, descrevemos o protocolo experimental utilizado para a aquisição dos sinais EMG, as etapas apresentadas no pseudocódigo e as ferramentas para a rotulagem das classes.

#### 5.1.2.1 Sistema para aquisição de dados

Atualmente, vários sistemas de aquisição de sinais eletromiográficos estão disponíveis no mercado, diferenciando-se basicamente pelos recursos incorporados, alguns possuindo apenas a instrumentação e um baixo custo e outras plataformas com maior poder de processamento, possuindo, por exemplo, condicionador de sinal em cada canal de aquisição e recursos de otimização da capacidade de armazenamento de energia das baterias recarregáveis, aumentando seu preço final. O APÊNDICE A apresenta os cinco sistemas de instrumentação de baixo custo analisados para aquisição de sinais EMG. Três dos cinco sistemas de aquisição utilizam a plataforma Arduino para o processamento dos sinais: e-Health, MyoWare e Olimex.

Para a escolha do sistema de baixo custo para aquisição de sinais EMG, três fatores foram levados em consideração: o custo, o número de canais EMG e duas métricas para a qualidade de sinais elétricos em sistemas de processamento: o SNR (*Signal-to-Noise Ratio* ou razão sinal-ruído) e o *crosstalk*. Na análise qualitativa SNR, quanto maior o seu valor (razão entre o sinal medido e o ruído presente) maior será a redução do ruído (DELSYS, 2006). Para a métrica *crosstalk*, quanto menor o seu valor, menor será a interferência do sinal entre os canais de medição.

No trabalho apresentado por Guerreiro *et al.* (2014), os autores realizaram uma avaliação comparativa entre as plataformas Arduino (Pro Mini e Uno) e BITalino para as métricas de qualidade de sinais elétricos citadas. A plataforma Arduino apresentou um valor de 23,97 dB enquanto o sistema BITalino apresenta 55,72 dB para o SNR. Para a métrica *crosstalk*, o kit Arduino apresentou valor de - 0,43 dB e o BITalino de -61,96 dB. Nas pesquisas realizadas, não foram encontradas informações destas métricas para o bracelete gForce. Desta forma, se comparadas as plataformas que utilizam Arduino como sistema de processamento (e-Health, MyoWare e Olimex) a escolha é pelo sistema BITalino. Em se tratando de número de canais EMG, a maioria das plataformas suporta apenas um canal. No caso do modelo MyoWare seria necessário adquirir 6 kits (número máximo empilhável). A plataforma gForce possui 8 canais EMG e a BITalino suporta comunicar, simultaneamente, dois ou mais módulos de aquisição, cada um com 6 canais de sinais EMG. Com base nas informações anteriores, percebe-se que a plataforma BITalino possui um bom custo-benefício em relação processamento e comunicação já embarcados, número de canais EMG e dimensões e foi a plataforma de aquisição de sinais EMG adotada para este projeto.

O sistema BITalino foi desenvolvido e produzido pelo Instituto de Telecomunicações de Portugal em parceria com a PLUX - Wireless Biosignals S.A. e é baseado no mesmo microcontrolador da plataforma Arduino Uno R3, o ATmega328P. Possui também um bloco gerenciador de energia, um sistema de comunicação sem fio com módulo Bluetooth v2.0 (alcance até 10 m) e permite coletar até 6 canais de dados (4 de 10 bits e 2 de 6 bits). Das diversas versões fabricadas, foi utilizado o modelo MuscleBIT (figura 28), desenvolvido para medição de atividade eletromiográfica. Este sistema possui capacidade de utilizar dois eletrodos na configuração bipolar, possui uma largura de banda de 10 a 400 Hz e CMRR (*Common Mode Rejection Ratio* ou Relação de Rejeição em Modo Comum) de 110 dB.

Figura 28 - Plataforma BITalino, modelo MuscleBIT




Fonte: adaptado de BITalino (2020).

Para a aquisição dos sinais EMG e rotulagem do banco de dados local, denominado KidoPro foram utilizados os seguintes recursos e equipamentos apresentados na figura 29 e descritos a seguir:

- Um computador posicionado na frente do voluntário para a visualização dos gestos/movimentos de mão;
- Dois módulos de aquisição de sinais EMG modelo MuscleBIT da empresa PLUX - Wireless Biosignals S.A. Cada módulo de aquisição possui quatro entradas analógicas que operam com conversores A/D de 10 bits de quantização a uma frequência de amostragem de 1 kHz (maior frequência que pode ser definida neste sistema);
- Oito condicionadores de sinais EMG da empresa PLUX - Wireless Biosignals S.A.;
- Dezesesseis eletrodos de superfície Ag/AgCl para os oito canais EMG e dois eletrodos de superfície para referência (um para cada módulo de aquisição de sinais EMG);
- Conjunto de cabos para conexão dos condicionadores de sinais aos módulos de aquisição, conexão dos eletrodos de referência aos módulos de aquisição e para sincronização dos módulos de aquisição;
- Um cronômetro;
- Um computador com o programa Opensignals (empresa PLUX - Wireless Biosignals S.A.) para visualização e armazenamento dos dados adquiridos e o programa Spyder (Python) para elaboração dos algoritmos de rotulagem dos sinais.

Figura 29 - Foto do arranjo experimental utilizado para a aquisição de sinais EMG: (1) computador para a visualização dos gestos/movimentos de mão; (2a e 2b) arranjo de dois módulos de aquisição de sinais EMG; (3) dezesseis eletrodos de superfície para os oito canais EMG e dois eletrodos (de superfície) para referência; (4) condicionadores de sinais; (5a e 5b) conjunto de cabos para conexão dos condicionadores de sinais aos módulos de aquisição; (6a e 6b) cabos para conexão dos eletrodos de referência aos módulos de aquisição; (7) cabo de sincronização dos módulos de aquisição; (8) computador com programa para a aquisição e registros dos sinais EMG.



Fonte: elaborado pelo autor (2021).

A metodologia para aquisição dos sinais eletromiográficos seguiu as recomendações do SENIAM (acrônimo para o consórcio europeu Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles - Eletromiografia de superfície para a avaliação não invasiva) (SENIAM, 2021; HERMENS *et al.*, 2000).

#### 5.1.2.2 Considerações éticas

Todos os procedimentos adotados nesta pesquisa obedeceram aos Critérios da Ética em Pesquisa com Seres Humanos conforme Resolução nº. 466/2012 do Conselho Nacional de Saúde e foram aprovados pelo Comitê de Ética em Pesquisa da UNISINOS sob o Certificado de Apresentação de Apreciação Ética (CAAE) número 12038819.9.0000.5344. Os participantes não receberam remuneração e nenhum tipo de recompensa nesta pesquisa, sendo sua participação voluntária. As informações desta pesquisa são confidenciais e poderão ser divulgadas, apenas, em eventos ou publicações, sem a identificação dos voluntários.

### 5.1.2.3 Procedimentos para a aquisição dos sinais EMG

Antes do início da aquisição dos sinais, todos os participantes receberam uma explicação do experimento de aquisição (de forma escrita e oral) e assinaram um Termo de Livre Consentimento (de acordo com o Comitê de Ética em Pesquisa da Universidade) para participar da sessão. O termo de consentimento padrão é apresentado no APÊNDICE C. Em seguida foi realizada uma anamnese para se ter conhecimento de alguma situação ou característica(s) relevante(s) dos voluntários. O documento da anamnese encontra-se no APÊNDICE D.

Cinco participantes saudáveis foram incluídos neste estudo e suas informações básicas são apresentadas na tabela 4. Todos os participantes fisicamente aptos são destros.

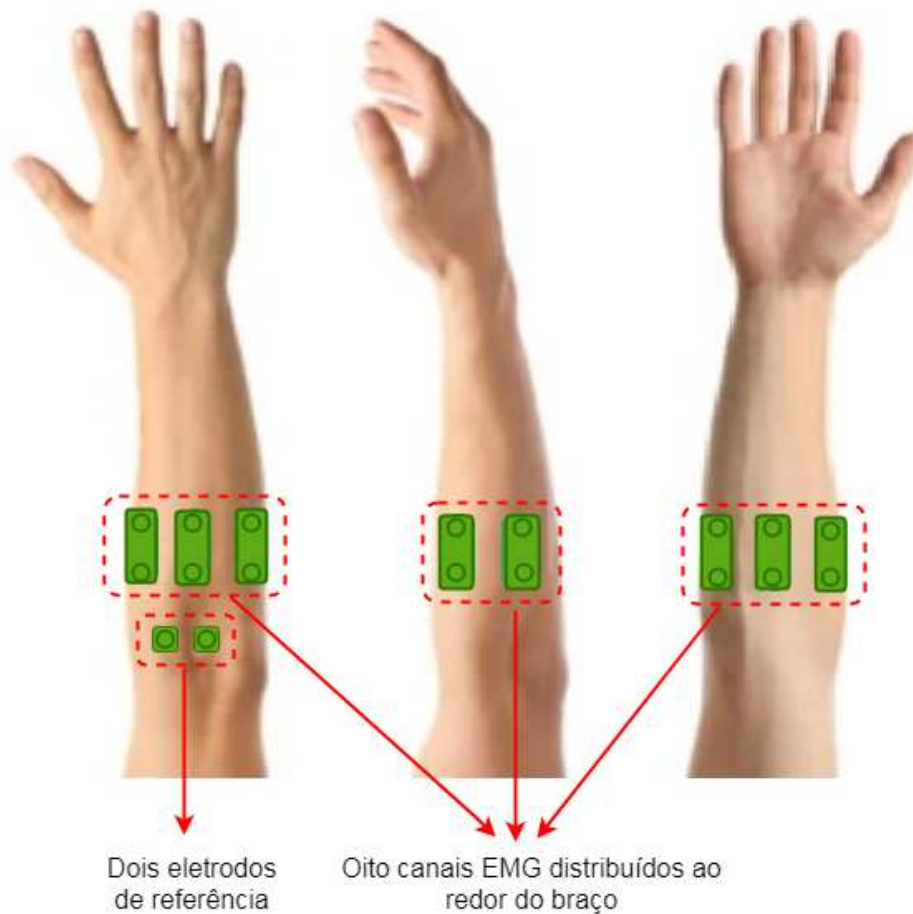
Tabela 4 - Informações dos voluntários do banco de dados local

<b>Sujeito</b>	<b>Idade (anos)</b>	<b>Gênero</b>	<b>Altura (m)</b>	<b>Peso (kg)</b>
1	40	M	1,75	75,0
2	41	M	1,74	68,0
3	40	F	1,65	73,0
4	36	M	1,85	78,0
5	33	F	1,56	57,0

Fonte: elaborado pelo autor (2021).

Para o experimento, os voluntários foram convidados a sentarem-se confortavelmente em uma cadeira de escritório e a apoiarem os dois braços em uma mesa. Após foi realizada a etapa de fixação dos eletrodos que consiste na seguinte metodologia: a) limpar a pele dos participantes com álcool isopropílico a 70% e depilar a região de interesse; b) fixar, de forma igualmente espaçada ao redor do antebraço direito (ou esquerdo) dos participantes, oito pares de eletrodos de superfície Ag/AgCl (figura 30). Cada par de eletrodos foi posicionado na direção longitudinal em relação às fibras musculares da região de interesse; c) fixar dois eletrodos de referência na região do cotovelo; d) interligar os eletrodos as plataformas MuscleBIT, onde cada plataforma recebe 4 canais de medição e um canal de referência.

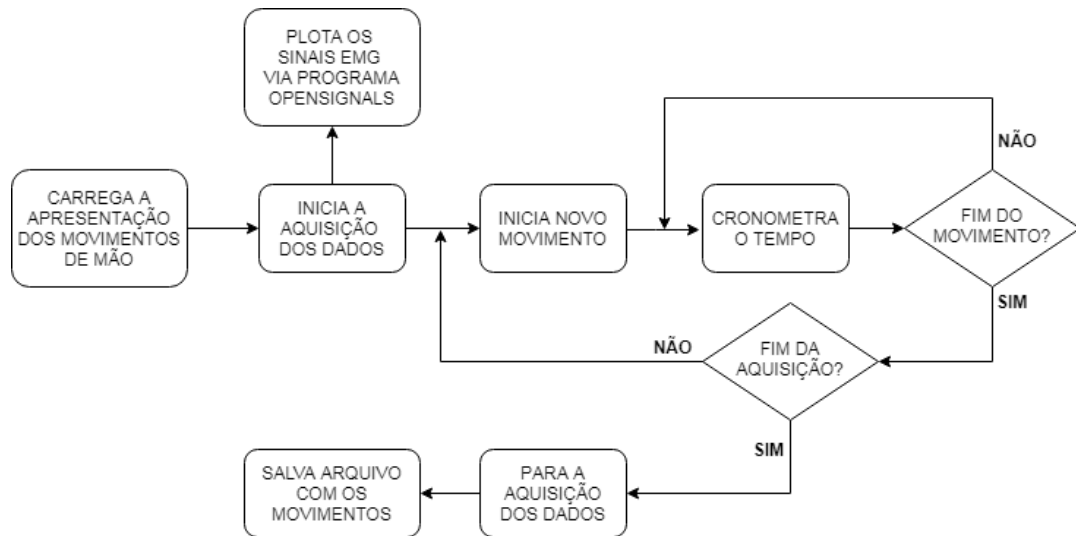
Figura 30 - Posicionamento e fixação dos eletrodos no braço de cada voluntário



Fonte: elaborado pelo autor (2021).

Antes da sessão de aquisição, foram apresentados no computador os gestos e movimentos e após, os voluntários realizaram uma sequência de treinamento que envolve três repetições dos movimentos para se acostumar com o protocolo. Então o processo de aquisição é iniciado utilizando como recursos um cronômetro e um computador onde os voluntários foram instruídos no monitor com a apresentação da imagem dos gestos/movimentos. A figura 31 apresenta o fluxograma do ensaio de aquisição.

Figura 31 - Fluxograma para procedimento de aquisição e gravação dos sinais EMG



Fonte: elaborado pelo autor (2021).

Cada voluntário foi solicitado a realizar seis repetições de cada movimento, iniciando na posição relaxada. Cada repetição de movimento foi realizada por 5 s de contração, intercalados com pausas de 5 s para permitir ao voluntário descansar. O experimento consistiu em 11 gestos/movimentos de mão (incluindo repouso) dividido em duas sessões com duração de 300 s cada.

#### 5.1.2.4 Movimentos/gestos de mão para banco de dados KidoPro

Foram considerados 10 movimentos de mão e punho para a formação do banco de dados desta tese, denotado KidoPro (quadro 4). Estes gestos foram inspirados nos trabalhos de Raurale e colaboradores (2020) e Zhai *et al.* (2017) e no banco de dados NinaPro DB2 (ATZORI *et al.*, 2014a). Os diferentes movimentos realizados, intercalados por uma aula de descanso, foram: fechamento de mão, polegar para cima, mão aberta, pinça fina, pinça de aperto, pinça esférica, envoltório médio, pronação e supinação do punho e ferramenta de preensão.

Quadro 4 - Movimentos usados para o banco de dados KidoPro

Classe	Descrição	Imagem	Atzori <i>et al.</i> (2014a)	Raurale <i>et al.</i> (2020)	Zhai <i>et al.</i> (2017)
0	Repouso		X	X	
1	Mão fechada		X	X	X
2	Polegar		X		
3	Mão aberta		X	X	X
4	Pinça fina		X		X
5	Pegada cilíndrica		X		
6	Pronação de punho		X	X	X
7	Supinação de punho		X	X	X
8	Pegada esférica		X		
9	Ferramenta de apreensão				X
10	Agarrar a tampa		X		X

Fonte: elaborado pelo autor (2021).



Nosso banco de dados possui características semelhantes ao NinaPro DB2 e DB3 com seis repetições de movimentos e todos os gestos de mão foram alternados com um movimento de repouso intermediário). A figura 32 apresenta a imagem de um ensaio realizado.


Figura 32 - Imagem do ensaio realizado



Fonte: elaborado pelo autor (2021).

Para exemplificar, apresentamos na figura 33 a aquisição do sistema BITalino, com os oito canais EMG, de um trecho com seis repetições de um dos movimentos do banco de dados.

Figura 33 - Aquisição de sinais EMG com os oito canais do sistema BITalino (Banco de dados KidoPro, sujeito 2, classe 1)



Fonte: elaborado pelo autor (2021).

Após a aquisição dos sinais EMG dos voluntários locais, foi realizada a etapa de rotulagem (*labeling*) de cada movimento, sendo descrita na seção seguinte.

#### 5.1.2.5 Processamento dos dados adquiridos

Os sinais EMG obtidos pelos sistemas MuscleBIT são sinais brutos (faixa de 0 a 1023) e foram convertidos para valores de tensão (faixa de -1,65 mV a +1,65 mV) através da equação 15:

$$\text{EMG (volts)} = \frac{\left(\frac{x_i}{1023} - 0,5\right) 3,3}{1000}, \quad (15)$$

onde  $x_i$  é o valor bruto do sinal EMG adquirido.

Após a aquisição dos sinais EMG, foi necessário marcar onde, no fluxo de dados, o sujeito está realizando cada gesto/movimento de mão. Esta é uma das etapas mais desafiadoras no processo de classificação de sinais EMG, pois existe uma região de transição entre os movimentos que muitas vezes apresenta sinais de baixa amplitude, pouco distintos e sobrepostos entre as classes (CENE e BALBINOT, 2018). Existem diferentes métodos/abordagens para estimar o momento da ativação e desativação EMG, entre eles podemos citar a distância *Generalized Likelihood Ratio* (GLR) que consiste em dividir a janela de movimento em três segmentos (repouso, movimento, repouso), marcados pelos pontos  $t_0$  e  $t_1$ . Os pontos de mudança são determinados utilizando o conceito de máxima verossimilhança, ou seja, a maximização da probabilidade de cada amostra permitindo verificar qual classe ela melhor representa: movimento ou repouso (ATZORI *et al.*, 2015). Outra técnica é o Operador de Energia de Teager-Kaiser (TKEO - Teager-Kaiser *Energy Operator*). Neste método os dados são primeiramente filtrados por passa-banda e em seguida o Operador de Energia de Teager-Kaiser é aplicado, fornecendo um sinal transformado  $y(n)$ , como em (16) (SOLNIK *et al.*, 2010):

$$y(n) = x^2(n) - x(n+1)x(n-1), \quad (16)$$

onde  $x(n)$  é o sinal EMG e  $n$  é o número da amostra.

Após aplicação do operador, o sinal  $y(n)$  é retificado e filtrado, formando um envelope. Para a estimativa do tempo de ativação e desativação, é utilizado o método baseado em um valor de limiar (*threshold*), onde se determina os tempos em que o envelope do sinal excede um valor limite (SOLNIK *et al.*, 2010). O valor de limiar  $l$  é dado por (17):


$$l = \mu + J\sigma, \quad (17)$$

onde  $\mu$  e  $\sigma$  são, respectivamente, a média e o desvio padrão do envelope durante um período de inatividade e  $J$  é uma constante.

Li *et al.* (2007) relatam que o método TKEO fornece tempos de ativação do sinal EMG mais precisos do que os métodos de envelope linear ou método GLR, especialmente quando a razão sinal-ruído é baixa. Neste trabalho foi utilizado o Operador de Energia de Teager-Kaiser, onde uma rotina da técnica, disponibilizada pela empresa fornecedora dos módulos MuscleBIT/BITalino, foi adaptada para a marcação do início e término da ativação muscular. O canal principal (aquele com sinal de maior amplitude) foi selecionado e aplicado o operador para rotular quando uma contração começa e termina de forma consistente para todos os oito canais, sendo valor limite (*threshold*) definido empiricamente.

Para comparações e validação, foram utilizados os métodos de inspeção visual e detecção por envelope linear (retificação seguida de um filtro passa-baixas). A detecção por envelope linear foi projetada para um filtro do tipo *Butterworth* de segunda ordem com frequência de corte de 7 Hz e valor de limiar definido empiricamente. A figura 34 apresenta as marcações de um trecho (classe 1) do banco de dados utilizando TKEO e envoltória: em (a) os sinais EMG (canais 6 e 7), em (b) o sinal após aplicação do TKEO, retificação e filtragem e em (c) a marcação (*label*) da classe.


Figura 34 - Marcação de início e término da atividade muscular (Banco de dados KidoPro, sujeito 2, classe 1)



Fonte: elaborado pelo autor (2021).

Para fins de comparação, o procedimento com o operador TKEO foi aplicado em um trecho do banco de dados NinaPro DB2 (movimento/classe 3 do sujeito 8). Este banco de dados utiliza a distância GLR para determinar o momento da ativação e desativação EMG. A figura 35 apresenta as marcações para cada técnica: em (a) o sinal EMG (canal 0), em (b) o sinal após aplicação do Operador de Energia de Teager-Kaiser (seguido das etapas de retificação e filtragem) e em (c) marcações (*label*) da classe pelos métodos TKEO e GLR.

Figura 35 - Marcação de início e término da atividade muscular (Banco de dados NinaPro DB2, sujeito 8, classe 3)



Fonte: elaborado pelo autor (2021).

Os resultados apresentam marcações semelhantes durante a ativação muscular e diferenças mais significativas na desativação EMG. Isto se deve ao valor de limiar ajustado na técnica TKEO: aumentos do valor atrasam a determinação do início do movimento/gesto, enquanto reduções do valor provocam o aparecimento de falsas classes de movimento durante o segmento repouso.

Para cada participante e conjunto de exercícios, o banco de dados KidoPro contém um arquivo com tamanho de 21,2 MB no formato .txt (formato de texto) com as seguintes colunas apresentadas no quadro 5.

Quadro 5 - Formatação do banco de dados KidoPro

Coluna	Descrição
1	Número do exercício (classe). Matriz de $M$ linhas x 1 coluna, onde cada linha apresenta uma amostra no tempo do movimento realizado pelo voluntário.
2	Número da repetição. Matriz de $M$ linhas x 1 coluna, onde cada linha apresenta uma amostra no tempo do número de repetição do movimento realizado pelo voluntário.
3 - 10	Canais EMG. Matriz de $M$ linhas x 8 colunas, onde cada coluna apresenta o valor de um dos eletrodos de superfície (no caso 8 canais) e cada linha apresenta uma amostra no tempo.

Fonte: elaborado pelo autor (2021).

Esta primeira versão do banco de dados é disponibilizada para download no repositório <https://github.com/eng-olegario/prosthesis-control>. A figura 36 ilustra um trecho (cabeçalho e algumas linhas de dados) do *dataset* de um dos voluntários.

Figura 36 - Trecho do *dataset* KidoPro (voluntário 1)

```
#####
# Subject 1, Age: 40, Gender: M
# Devices: ["98:D3:91:FD:3F:95", "98:D3:91:FD:3F:9B"]
# Gesture: ["rest", "closed_hand", "thumb_up", "open_hand", "fine_pinch_grip", "medium_wrap",
           "pronation", "supination", "spherical_grip", "tool_grip", "chuck_grip"]
# Label: ["class", "repetition", "EMG_0", "EMG_1", "EMG_2", "EMG_3", "EMG_4", "EMG_5", "EMG_6", "EMG_7"]
# Sampling rate: 1000,
# Resolution: [4, 4, 10, 10, 10, 10, 10, 10, 10, 10]

0    1    504    503    501    507    505    499    509    508
0    1    503    508    504    506    507    504    510    508
0    1    504    511    504    509    507    513    509    507
0    1    502    512    504    507    507    516    511    509
0    1    503    511    505    508    506    517    509    507

#####
```

Fonte: elaborado pelo autor (2021).

Após a rotulagem do banco de dados KidoPro, a etapa de reconhecimento de movimentos de mão através dos sinais EMG foi aplicada para as formas *offline* e *online* (apresentadas na seção 6.2). O reconhecimento compreendeu as etapas de pré-processamento, janelamento, extração de *features* e classificação.

### 5.1.3 Pré-processamento

O pré-processamento contemplou três etapas: filtragem, retificação e normalização de cada canal de sinais EMG. Para remover ruídos de alta frequência, os biosinais passaram por um filtro passa-baixa *Butterworth* de 4ª ordem com frequência de corte de 450 Hz. Após esta etapa os sinais foram retificados e normalizados.

A retificação foi uma etapa essencial para obter a forma ou envelope do sinal EMG, já que essencialmente o sinal EMG tem seu valor médio próximo do zero (ROSE, 2011). Pode ser realizada de duas maneiras: retificação meia-onda onde os valores negativos são suprimidos do sinal (igualados a zero) e retificação onda completa, onde é utilizado o módulo dos sinais EMG (transforma os sinais EMG negativos em valores positivos). Neste trabalho, foi escolhida a retificação onda completa de forma a manter toda a energia do sinal. A função valor absoluto (equação 18) foi utilizada para retificar os sinais de cada um dos canais EMG.

$$EMG\_RET_{CH} = |EMG_{CH}|, \quad (18)$$

onde  $EMG_{CH}$  representa o sinal EMG de cada um dos oito canais de aquisição e  $EMG\_RET_{CH}$  representa o sinal EMG retificado por canal.


Na etapa seguinte, para poder comparar a atividade EMG no mesmo músculo em dias diferentes ou para comparar a atividade EMG entre músculos, os sinais EMG devem ser normalizados (DE LUCA, 1997). Quando o sinal EMG é normalizado, as diferenças entre os segmentos superior e inferior são reduzidas (LEHMAN e MCGILL, 1999). A equação 19 apresenta o sinal EMG normalizado.

$$EMG\_NORM_{CH} = \frac{EMG\_RET_{CH}}{\max(EMG\_RET_{CH})}, \quad (19)$$

onde  $EMG\_NORM_{CH}$  representa o sinal EMG normalizado de cada um dos oito canais de aquisição e  $EMG\_RET_{CH}$  representa o sinal EMG retificado por canal.

A figura 37 exemplifica um sinal EMG adquirido com seis repetições de um dos movimentos do banco de dados KidoPro (a), bem como as etapas de retificação (b) e normalização (c).

Figura 37 - a) Sinal EMG não processado; b) Sinal EMG retificado; c) Sinal EMG normalizado (banco de dados KidoPro, sujeito 4, canal 2, classe 4)



Fonte: elaborado pelo autor (2021).

#### 5.1.4 Segmentação por janelas deslizantes

Para a otimização dos hiperparâmetros, treinamentos e testes dos classificadores, os sinais foram segmentados por meio da técnica de janelas deslizantes. Nesta técnica, dois pontos principais precisam ser considerados: o comprimento da janela (número de amostras em um segmento) e o valor do incremento (deslocamento e inserção de novas amostras no segmento).

Para este ponto, testes preliminares foram realizados com diferentes segmentações e incremento de janela (100 ms/50 ms, 200 ms/100 ms e 250ms/125 ms) apresentados no subcapítulo 6.2.1. Através destes ensaios, o valor do comprimento utilizado foi de 200 ms (400 amostras para os bancos de dados NinaPro e 200 amostras para o banco de dados kidoPro) com valor do incremento da janela de 100 ms (200 amostras para os bancos de dados NinaPro e 100 amostras para o banco de dados kidoPro).

### 5.1.5 Extrator de características (*features*)

Para os classificadores foi necessária uma etapa de extração de características (*features*) dos sinais EMG. Neste estudo, 15 características no domínio do tempo foram testadas usando correlação linear estatística baseada em filtro (Coeficientes de Correlação de Pearson). Este método é usado para remover as características irrelevantes (RAURALE *et al.*, 2020). Os coeficientes de correlação foram avaliados e sete funções (que apresentaram coeficientes menores que 0,75) foram escolhidas para a classificação dos sinais. O quadro 6 apresenta as *features* envolvidas neste trabalho onde  $\mu$  é o valor médio do sinal EMG e  $\sigma$  é o desvio padrão do sinal EMG.

Quadro 6 - *Features* extraídas dos sinais EMG utilizadas nesta tese

<b>Feature</b>	<b>Equação</b>	<b>Descrição</b>
<i>Mean Absolute Value</i> (MAV)	$MAV = \frac{1}{N} \sum_{i=1}^N  EMG_i $	Apresenta a média dos valores absolutos da amplitude do sinal EMG na janela deslizante
<i>Root Mean Square</i> (RMS)	$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N (EMG_i)^2}$	Representa a potência média do sinal EMG, refletindo a atividade dos músculos
<i>Wave Length</i> (WL)	$WL = \sum_{i=1}^{N-1}  EMG_{i+1} - EMG_i $	Representa o comprimento cumulativo da forma de onda do sinal EMG
<i>log Root Mean Square</i> (logRMS)	$\log RMS = \log \left( \sqrt{\frac{1}{N} \sum_{i=1}^N (EMG_i)^2} \right)$	Pode indicar as diferenças na magnitude RMS, amplificando valores RMS absolutos relativamente pequenos
<i>Variance</i> (VAR)	$VAR = \frac{1}{N-1} \sum_{i=1}^N  EMG_i - \mu $	Apresenta a dispersão de uma distribuição de sinais EMG em comparação com a média
<i>Kurtosis</i> (KUR)	$KUR = \frac{1}{N} \sum_{i=1}^N \left( \frac{EMG_i - \mu}{\sigma} \right)^4$	Medida que destaca as fortes contrações de diferentes movimentos, dando mais nitidez a distribuição da amostra
<i>Skewness</i> (SKEW)	$SKEW = \frac{1}{N} \sum_{i=1}^N \left( \frac{EMG_i - \mu}{\sigma} \right)^3$	Indica o grau de assimetria observada em diferentes distribuições de contração muscular

Fonte: adaptado de Raurale *et al.* (2020) e Zhang *et al.* (2019).

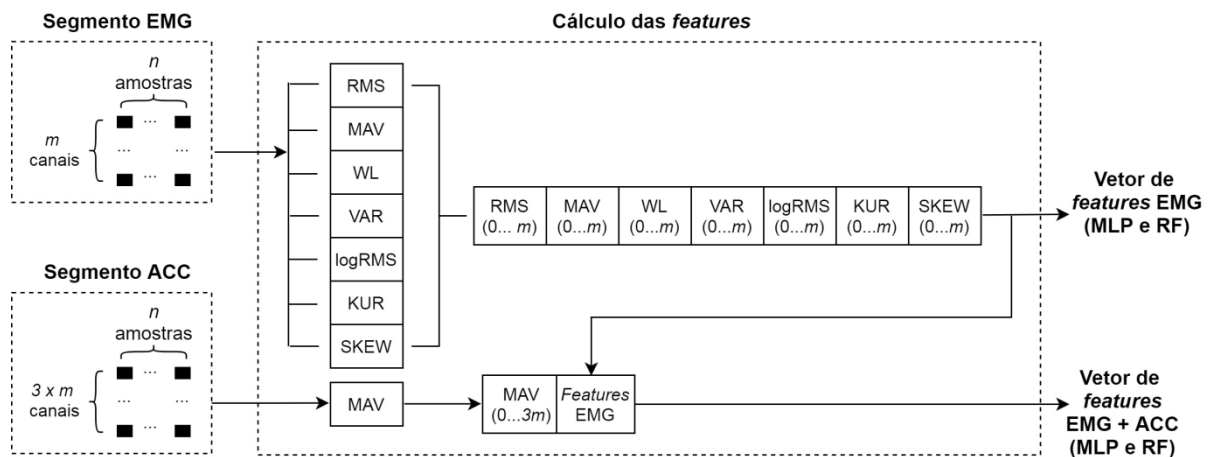
Apenas funções no domínio de tempo foram utilizadas, pois o uso de funções nos domínios da frequência e de tempo-frequência aumenta o custo computacional desta etapa (MOTOCHE e BENALCÁZAR, 2018).



### 5.1.6 Entrada dos classificadores

O processamento dos sinais de entrada depende do tipo de classificador e dos recursos utilizados em cada ensaio. Conforme apresentado na figura 38, o segmento EMG é formado é dado por um vetor  $u = m \times n$ , onde  $m$  é o número de canais EMG e  $n$  é o número de amostras de acordo com o tamanho da janela utilizado. O segmento ACC é composto por vetor  $w = 3.m \times n$  (para cada canal EMG, temos os três eixos do sensor ACC). Para os classificadores CNN e RNN, o segmento EMG é a própria entrada de dados (segmento EMG, por exemplo) para os métodos.

Figura 38 - Entrada de dados dos classificadores



Fonte: elaborado pelo autor (2021).

Para os ensaios dos bancos de dados NinaPro DB2 e DB3 com apenas sinais EMG e com os classificadores MLP e RF, nossa abordagem utilizou um total de 84 recursos EMG, com sete funções no TD e doze canais EMG. Para ensaios com sinais de acelerometria, empregamos ainda a função Valor Médio Absoluto (MAV) para calcular as *features* desta modalidade obtendo 36 valores de características ACC. Para o banco de dados KidoPro, a configuração com melhor desempenho utilizou no total 32 *features* EMG, com quatro funções no TD e oito canais EMG.

### 5.1.7 Conjuntos de treinamento e de teste

Os experimentos dos três bancos de dados (DB2 e DB3 do NinaPro e banco de dados KidoPro) seguiram a mesma metodologia de ATZORI *et al.* (2014a) e ATZORI *et al.* (2015) para a formação dos conjuntos de treinamento e teste, com a divisão dos dados baseada nas repetições dos movimentos. Desta forma a segunda e a quinta repetições de cada movimento foram usadas para o conjunto de teste, enquanto as quatro repetições restantes (1, 3, 4 e 6) foram usadas para o conjunto de treinamento.

### 5.1.8 Classificadores e otimização dos parâmetros

Para o primeiro ensaio, descrito na seção 5.1.1, quatro classificadores foram implementados (CNN, MLP, RF e RNN) e seus parâmetros foram ajustados para torná-los capazes de desempenhar bem o papel de generalizar dados não vistos, pois eles não são aprendidos durante o processo de treinamento da rede, e sim definidos pelo usuário no início do processo. Em seguida uma análise comparativa de classificação foi realizada, ordenando-os de acordo com a taxa de acerto de segmentos de sinais EMG provenientes de movimentos/gestos de mão. A seguir, são descritas as arquiteturas dos classificadores e os parâmetros otimizados para cada estrutura.

#### 5.1.8.1 Classificador MLP

A estrutura do algoritmo MLP tem uma camada de entrada, camada(s) escondida(s), função de ativação, camada *Softmax* e camada de saída com 12, 24 ou 50 neurônios dependendo do experimento realizado (número de classes). O tamanho da camada de entrada ( $u$ ) também foi determinado de acordo com o ensaio realizado: para os experimentos com o bloco de Redução da Dimensionalidade, o número de entradas foi estabelecido como  $k-1$  (onde  $k$  é o número de classes); para os ensaios sem o bloco de Redução da Dimensionalidade, o tamanho da entrada considerou as *features* extraídas (descritas na seção 5.1.5), o número de canais EMG e, quando utilizada, a quantidade de canais ACC (descritos na seção 5.1.6).

Testes preliminares foram realizados para determinar o número de camadas escondidas, número de neurônios em cada camada e tamanho do lote (*batch size*). Para os experimentos sem o bloco de Redução da Dimensionalidade, utilizamos duas camadas ocultas compostas por 600 e 200 neurônios, respectivamente; com o bloco Redução da Dimensionalidade, consideramos duas camadas ocultas compostas por 100 neurônios cada. A função de ativação usada foi *ReLU* e o otimizador empregado foi Adam. O treinamento da rede foi de 100 épocas e todos os filtros e pesos da rede foram inicializados com valores aleatórios.

#### 5.1.8.2 Classificador CNN

A estrutura CNN proposta consiste em uma camada de entrada, camada(s) de convolução, camada(s) de *pooling*, uma camada Totalmente Conectada (FC), camada *Softmax* e camada de saída com  $k$  neurônios (onde  $k$  é o número de classes). Os dados dos sinais EMG foram organizados no formato de uma matriz  $n \times m$ , onde  $n$  é o número de amostras de cada janela e  $m$  é o número de canais. Nesta estrutura CNN, foram testados os seguintes parâmetros: a quantidade de camadas de convolução (2 ou 3), o tamanho, número de filtros e passo de deslizamento (*stride*), *dropout* e *batch size*. A função de ativação usada foi *ReLU* e o otimizador empregado foi Adam. O número de épocas para treinamento foi 100 e todos os filtros e pesos da rede foram inicializados com valores aleatórios.

#### 5.1.8.3 Classificador RNN

Para a arquitetura RNN foram definidos os seguintes itens para sua implementação: camada de entrada com janelamento  $n \times m$  ( $n$  é o número de amostras de cada janela e  $m$  é o número de canais), camada(s) LSTM, uma camada Totalmente Conectada (FC), camada *Softmax* e camada de saída com  $k$  neurônios (onde  $k$  é o número de classes). O número de camadas LSTM e número de neurônios foram alterados para verificar o melhor desempenho entre as configurações. O tamanho do lote (*batch size*) e valor de *dropout* também foram testados. A função de ativação usada foi *ReLU*, o otimizador empregado foi Adam e o treinamento da rede foi de 100 épocas.

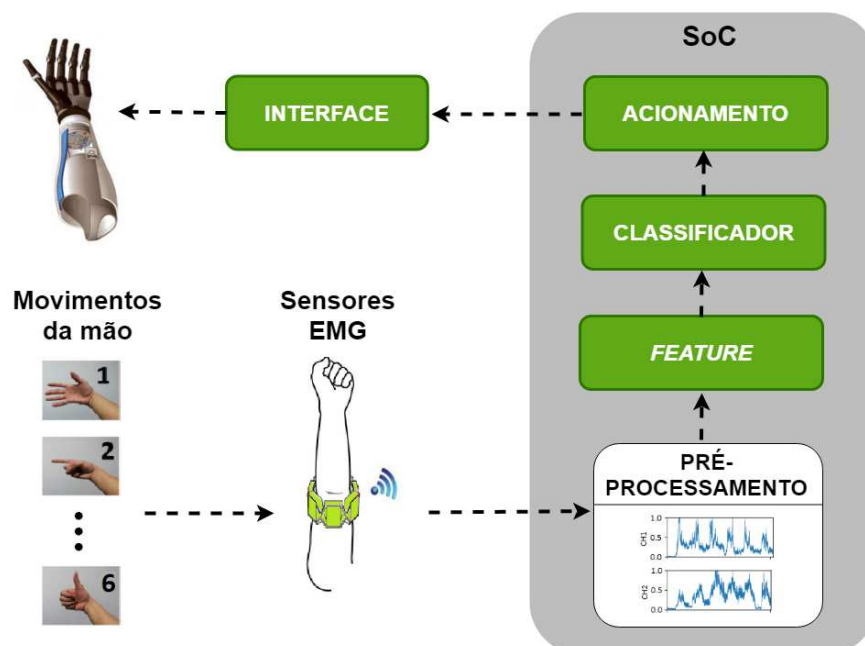
#### 5.1.8.4 Classificador RF

O tamanho da entrada ( $u$ ) do classificador RF foi determinado de da mesma forma que o classificador MLP: para os ensaios sem o bloco de Redução da Dimensionalidade, o número de entradas considerou as *features* extraídas (descritas na seção 5.1.5), o número de canais EMG e de número de canais ACC (quando utilizados); para os experimentos com o bloco de Redução da Dimensionalidade, o tamanho da entrada foi estabelecido como  $k-1$  (onde  $k$  é o número de classes). Para o classificador *Random Forest*, três parâmetros foram ajustados durante o treinamento pela ferramenta GridSearchCV. O número de árvores de decisão foi {10, 50, 100, 150, 200}, o número máximo de níveis foi {20, 50, 100, 150, 200} e o número total de recursos alimentados para o classificador {*auto*, *square root*}.

## 5.2 SISTEMA ONLINE

Após o processo de treinamento e validação dos classificadores no computador (*offline*) utilizando os dois bancos de dados (NinaPro e KidoPro), a arquitetura mais bem avaliada (em termos de classificação e portabilidade) foi implantada em uma plataforma de prototipagem SoC de baixo custo. A figura 39 apresenta o diagrama de blocos do sistema.

Figura 39 - Diagrama de blocos do sistema *Online*



Fonte: elaborado pelo autor (2021).

Este sistema mantém o *hardware* da instrumentação do sistema de aquisição de sinais EMG para realizar a medição de forma *real-time* e incorpora além das etapas de reconhecimento de movimentos/gestos de mão (pré-processamento, janelamento, cálculo das *features* e classificação), recursos para acionamento elétrico da prótese com objetivo de realizar a apreensão de objetos. Estes elementos são descritos a seguir. O custo deste protótipo é apresentado no APÊNDICE F.

### 5.2.1 Plataforma de prototipação rápida

O desenvolvimento de novos recursos para processamento de sinais, sensores e outros periféricos têm elencado o surgimento de plataformas de prototipagem de baixo custo. Estas plataformas, também chamadas de SoC (*System On Chip*), são modelos de computadores com todo o hardware integrado em placa única (tais como processador, memória, Interfaces de comunicação, circuitos de gestão de energia e outras funcionalidades digitais, analógicas). Seu uso em pesquisas e desenvolvimento de aplicações está promovendo uma verdadeira revolução no mercado de microcontroladores e processamento de sinais. O APÊNDICE B apresenta os sistemas de prototipação rápida analisados.

Com base nas informações anteriores, percebeu-se que a plataforma Raspberry Pi possui um ótimo custo-benefício em relação processamento, memória, dimensões e custo. Esta plataforma foi adotada para este projeto. A Raspberry Pi desenvolvida pela Fundação Raspberry Pi no Reino Unido é um computador de baixo custo em placa única do tamanho de um cartão de crédito e possui arquitetura ARM baseada no SoC, comunicação via tecnologia *Bluetooth* e periféricos como conector de vídeo mini HDMI, portas USB (uma para alimentação e uma para dados) e entrada para cartão de memória microSD. Existem vários modelos e versões de placas Raspberry Pi disponíveis no mercado diferenciando basicamente pelo número de periféricos embarcados. Foi escolhido o modelo Raspberry Pi 3 B+ (figura 40) e suas especificações técnicas são apresentadas no quadro 7.

Figura 40 - Plataforma de prototipação Raspberry Pi 3 B+



Fonte: adaptado de Raspberry Pi (2018).

Quadro 7 - Especificações da plataforma Raspberry Pi 3 B+

Descrição	Especificação
Processador	Broadcom BCM2837B0, Cortex-A53 (ARMv8) 64-bit SoC @ 1,4GHz.
Memória	1 GB RAM LPDDR2
Comunicação	Wi-Fi 2,4 GHz e 5 GHz 802.11b/g/n/ac, Bluetooth 4.2 e Bluetooth Low Energy (BLE)
Alimentação	5 V/2,5 A
Periféricos	PWM, SPI, I <sup>2</sup> C, UART, HDMI, USB (4)
Tamanho da placa	85 mm x 56 mm x 17 mm

Fonte: adaptado de Raspberry Pi (2018).

Esta placa ainda possui 40 pinos chamados de GPIO (*General Purpose Input Output*) utilizados como entrada/saída de propósito geral. Também tem módulo PWM e três (3) interfaces de comunicação serial: UART (Receptor/Transmissor Universal Assíncrono, do inglês *Universal Asynchronous Receiver/Transmitter*), SPI (Interface Serial de Periféricos, do inglês *Serial Peripheral Interface*) e I<sup>2</sup>C (Circuito Inter-Integrado, do inglês *Inter-Integrated Circuit*). A plataforma pode rodar diversas distribuições Linux como o Raspbian e Ubuntu.

### 5.2.2 Elementos de *software* do sistema *Online*

Os elementos de programação implementados são apresentados no quadro 8 na forma de um pseudocódigo. Todas as rotinas foram elaboradas em linguagem Python, utilizando o *framework* de código aberto TensorFlow Lite (TENSORFLOW LITE, 2019). Após carregar o arquivo com as configurações e parâmetros do classificador treinado na etapa *offline*, o sistema estabelece comunicação (*Bluetooth*) com a plataforma BITalino e inicia a aquisição. Os sinais EMG são adquiridos pelas duas plataformas MuscleBIT/BITalino com quatro canais (cada), totalizando oito canais EMG. Os valores dos canais amostrados são convertidos em uma matriz e a janela EMG é atualizada com estes novos dados. Após, ocorre a extração das *features* e o movimento é classificado. Esta informação então é enviada ao módulo de acionamento da prótese.

Quadro 8 - Etapas pseudocódigo do sistema de classificação *online*

<p><b>Início</b></p> <p>Carrega o arquivo com as configurações e parâmetros do classificador</p> <p>Inicializa o(s) dispositivo(s) de aquisição de sinais EMG</p> <p>enquanto loop = 1 faça</p> <p style="padding-left: 20px;">Realiza a aquisição dos sinais EMG (dados brutos)</p> <p style="padding-left: 20px;">Pré-processamento</p> <p style="padding-left: 40px;">Ajuste da escala</p> <p style="padding-left: 40px;">Atualiza o segmento EMG</p> <p style="padding-left: 40px;">Retificação</p> <p style="padding-left: 20px;">Calcula as <i>features</i></p> <p style="padding-left: 20px;">Realiza a redução da dimensionalidade</p> <p style="padding-left: 20px;">Executa classificador treinado</p> <p style="padding-left: 20px;">Comunica com a interface da prótese o movimento classificado</p> <p style="padding-left: 20px;">Define as posições dos servos motores com base na classificação</p> <p style="padding-left: 20px;">Ativa a prótese para imitar o gesto</p> <p>Fimenquanto</p> <p><b>Fim</b></p>
---

Fonte: elaborado pelo autor (2021).


Para o sistema embarcado da prótese *open source* (chamado no diagrama de blocos do sistema *Online de interface*) utilizamos uma plataforma Arduino para estabelecer o acionamento elétrico dos cinco servomotores. As rotinas de comunicação com a plataforma Raspberry PI e acionamento das saídas digitais para acionamento e imitação dos gestos de mão foram escritas em linguagem C.

Testes preliminares para a determinação do janelamento (apresentados na seção 6.2.1) e extração de características foram realizados no sistema *offline* e adotados no sistema implantado na plataforma SoC. A configuração de janelas deslizantes com comprimento de 200 ms e incremento de 100 ms e o conjunto com quatro funções TD (RMS, MAV, VAR e WL) apresentaram os melhores resultados.

### 5.2.3 Sistema Mecânico

A prótese de mão usada para os testes de preensão de objetos é uma adaptação da plataforma robótica de código aberto chamada *Hand Robot InMoov* (figura 41), desenvolvida pelo escultor e designer francês Gaël Langevin. A *Hand Robot InMoov* é um subprojeto do *Robot InMoov*, primeiro robô humanóide em tamanho real que pode ser criado em impressoras tridimensionais.

Figura 41 - Prótese de mão *Hand Robot inMoov*



Fonte: adaptado de Langevin (2018).

Esta prótese possui como principais características: grande similaridade anatômica com a mão humana, 17 juntas e 5 dedos ativados individualmente (totalizando 5 graus de liberdade) através de servomotores, permitindo uma alternância de força de preensão dedo a dedo (LANGEVIN, 2018). Para validar o *software* e o *hardware* construídos para o reconhecimento dos movimentos/gestos de mão e acionamento da mão protética, dois experimentos foram realizados e são descritos a seguir.



### 5.2.4 Experimentos no sistema *Online*

Antes dos experimentos, todos os participantes receberam uma explicação dos procedimentos (de forma escrita e oral) e assinaram um termo de consentimento para participar das sessões. O primeiro experimento teve como objetivo avaliar o classificador implantado na plataforma de prototipagem de baixo custo. Na plataforma foram desenvolvidas as rotinas para leitura do bracelete de sensores EMG via comunicação *Bluetooth*, pré-processamento, janelamento, cálculo das *features* e predição. O protocolo para este experimento com os voluntários é descrito a seguir:

- Para o experimento, os voluntários foram convidados a sentarem-se confortavelmente em uma cadeira de escritório e a apoiarem os dois braços em uma mesa. Após foi realizada a etapa de fixação dos eletrodos, já descrita na seção 5.1.2.3;
- No início do experimento, para se acostumar com o protocolo, cada voluntário realizou sequências dos onze gestos de mão (descritos na seção 5.1.2.4), onde cada movimento foi mantido por 3 s, seguido do gesto de repouso, também mantido por um tempo de 3 s. Os gestos foram apresentados através de uma sequência de imagens no computador;
- Após, foi solicitado que o voluntário realizasse novamente os gestos de mão, mantendo por 3 s e intercalando com o movimento de repouso (também por 3 s);
- Durante o ensaio de cada voluntário, os gestos realizados foram salvos em um arquivo .txt.

O segundo ensaio envolveu a realização dos gestos de mão pela prótese, a pega de objetos e o seu deslocamento entre dois pontos previamente determinados. Devido às limitações do sistema mecânico (mão protética), dois movimentos foram formatados para que o dispositivo pudesse apresentar o gesto classificado: para o movimento de pronação a prótese executou a letra V (dedos indicador e médio estendidos e os demais flexionados) e para supinação a mão protética executou a letra W (dedos indicador, médio e anelar estendidos e os demais flexionados). A tabela 5 apresenta a posição angular de cada motor para cada gesto executado.

Tabela 5 - Posição angular de cada motor para cada gesto executado


Classe	Descrição	Posição angular de cada motor para cada gesto (°)				
		Polegar (servo 1)	Indicador (servo 2)	Médio (servo 3)	Anelar (servo 4)	Mínimo (servo 5)
0	Repouso	0	0	0	0	0
1	Mão fechada	100	90	50	90	70
2	Polegar	0	90	60	90	70
3	Mão aberta	0/60/0	0/60/0	0/60/0	0/60/0	0/60/0
4	Pinça fina	90	100	0	0	0
5	Pegada cilíndrica	70	90	90	90	70
6	Pronação de punho	100	0	0	100	100
7	Supinação de punho	100	0	0	0	100
8	Pegada esférica	90	100	70	100	130
9	Ferramenta de preensão	90	100	80	90	90
10	Agarrar a tampa	80	80	80	100	80

Fonte: elaborado pelo autor (2021).

Um protocolo para o experimento de preensão e deslocamento de objetos foi desenvolvido e é descrito a seguir:

- Três objetos foram utilizados no ensaio: bola de tênis, garrafa plástica de 600 ml e um objeto retangular;
- Para o experimento, os voluntários foram convidados para se posicionarem à frente da mesa. Após foi realizada a etapa de fixação dos eletrodos, já descrita na seção 5.1.2.3;
- Conforme ilustra a figura 42, duas linhas paralelas com distância de 100 cm foram marcadas na superfície da mesa de comprimento de 240 cm, largura de 60 cm e altura de 75 cm;
- A prótese foi colocada sobre a mesa e o voluntário a suportou com a mão hábil (sem os eletrodos de superfície);

Figura 42 - Experimento para preensão e deslocamento de objeto



Fonte: elaborado pelo autor (2021).

- No início do experimento, para se acostumar com o protocolo, cada voluntário realizou uma sequência de treinamento que envolveu repetições para pega de cada um dos objetos. O voluntário executou o movimento apresentado em uma imagem, e com a prótese realizou a pega do objeto que estava sobre a mesa na linha A, o deslocou até a linha B, e fez o gesto de descanso;
- Após, os três objetos foram alinhados ao longo da linha A e solicitado que cada voluntário realizasse em uma única rodada, o gesto de preensão de cada objeto, deslocando a prótese da posição A (partida) para a posição B. Em seguida, o voluntário fez o movimento de descanso para soltar o objeto na linha B. A rodada foi repetida 10 vezes;
- Se o objeto caísse na mesa durante a elevação ou movimentação, ele era colocado de volta ao ponto de partida pelo voluntário (a mão hábil largava a prótese, posicionava o objeto sobre a linha A e pegava novamente a mão protética) e o ensaio de preensão e deslocamento era reiniciado;
- No experimento, foi considerado erro de execução toda vez que um objeto caísse da mesa;
- Para cada preensão e movimentação de objeto, um examinador anotava o tempo para transferência de cada objeto e o tempo de conclusão da rodada.

Para avaliação dos sistemas de classificação, descrevemos na próxima seção as métricas utilizadas para quantificar o desempenho *offline* e *online*.

### 5.3 AVALIAÇÃO DOS SISTEMAS DE RECONHECIMENTO DE GESTOS

A avaliação dos classificadores foi realizada através de matriz de confusão e de uma métrica de qualidade que calcula a taxa de acerto de segmentos de sinais EMG provenientes dos gestos/movimentos de mão realizados pelos voluntários. No sistema Online também foi avaliado o desempenho computacional dos componentes de software desenvolvidos. Estes métodos são descritos a seguir.

#### 5.3.1 Matriz de confusão

Após a construção dos classificadores, foi necessário um método para avaliar quantas instâncias foram classificadas corretamente e incorretamente em cada classe do problema. Isto pode ser realizado através de uma matriz de confusão, mostrada na tabela 6. Os resultados são apresentados em duas dimensões: classes verdadeiras e classes preditas, para  $n$  classes diferentes ( $C_1, C_2, \dots, C_n$ ).

Tabela 6 - Matriz de confusão de um classificador

Classe	Predita $C_1$	Predita $C_2$	...	Predita $C_n$
Verdadeira $C_1$	$M(C_1, C_1)$	$M(C_1, C_2)$	...	$M(C_1, C_n)$
Verdadeira $C_2$	$M(C_2, C_1)$	$M(C_2, C_2)$	...	$M(C_2, C_n)$
⋮	⋮	⋮	⋮	⋮
Verdadeira $C_n$	$M(C_n, C_1)$	$M(C_n, C_2)$	...	$M(C_n, C_n)$

Fonte: elaborado pelo autor (2021).

Este número de acertos, para cada classe, se localiza na diagonal principal  $M(C_i, C_i)$  da matriz. Os demais elementos  $M(C_i, C_j)$ , para  $i \neq j$  representam os erros da matriz. Desta forma, quando um exemplo positivo é classificado como positivo, ele é denominado Verdadeiro Positivo (TP - *True Positive*). Se o exemplo negativo é classificado corretamente, temos o Negativo Verdadeiro (TN - *True Negative*). Ainda são possíveis dois erros, o Falso Positivo (FP- *False Positive*) e Falso Negativo (FN - *False Negative*).

### 5.3.2 Métricas de avaliação de classificação

Em problemas de classificação, o objetivo das métricas de avaliação é comparar a resposta estimada pelo modelo em relação ao rótulo (*label*) verdadeiro, que representa o valor referente a uma das  $k$  classes existentes. Duas métricas foram utilizadas para avaliar numericamente o desempenho dos classificadores implementados neste trabalho: a acurácia geral e a acurácia ponderada. A acurácia geral, apresentada na equação (20) é a taxa de acerto em relação à quantidade de instâncias testadas. É o método de avaliação preferido para medir o desempenho de classificadores (ORTIZ-CATALAN *et al.*, 2015; CENE *et al.*, 2019) e foi a principal métrica utilizada para comparação entre os sistemas desenvolvidos nesta tese e os métodos apresentados na literatura existente.

$$Acurácia\ geral\ (\%) = \left( \frac{\text{Número de segmentos classificados corretamente}}{\text{Número total de segmentos classificados}} \right) \cdot 100\% \quad (20)$$

A acurácia ponderada, apresentada na equação (21), considera todas as classes para compor a média final sem o viés (bias) causado pela classe repouso, em um banco de dados desbalanceado (CENE *et al.*, 2019). Quando o banco de dados é balanceado, as acurácias geral e ponderada apresentam os mesmos resultados.

$$Acurácia\ ponderada\ (\%) = \left( \frac{\text{Número de classificações corretas da classe } k}{\text{Número total de segmentos da classe } k} \right) \cdot 100\% \quad (21)$$

Ao invés da utilização da métrica acurácia, alguns estudos sobre classificação de gestos de mão através da eletromiografia acabam utilizando o erro de classificação (acurácia), apresentado na equação (22) (SANCHEZ-VELASCO *et al.*, 2020):

$$Erro\ de\ classificação\ (\%) = (1 - acurácia) \cdot 100\% \quad (22)$$

Com relação à análise estatística, todas as comparações de pares foram baseadas em *one-way* ANOVA seguida por análise *post-hoc* de Bonferroni. O nível de significância estabelecido foi de 5% ( $p < 0,05$ ).

### 5.3.3 Tempo de processamento do sistema *Online*

Para o sistema *Online*, além das acurácias geral e ponderada dos classificadores, foi avaliado o desempenho computacional nos diferentes componentes que compõem o sistema em tempo real implantado e operado na plataforma de prototipação rápida (Raspberry Pi). Estes componentes compreendem as etapas de pré-processamento, cálculo de *features* e classificação. Também foi avaliado o desempenho computacional do conjunto. Usamos as seguintes métricas: o tempo médio e desvio padrão para o processamento dos componentes e o tempo máximo de processamento esperado dentro de um intervalo de confiança de 95%, assumindo que os dados da amostra convergem para uma distribuição gaussiana. O sistema foi comparado com a literatura existente levando em consideração sistemas com números de classes similares.

### 5.3.4 Execução de tarefas no sistema *Online*

Para avaliar as tarefas de apreensão e movimentação de objetos no sistema *Online* a métrica de desempenho baseada na taxa de conclusão de tarefas (*CR - Completion Rate*) foi utilizada e é apresentada na equação (23) (Bl *et al.*, 2019):

$$CR = \frac{NTC}{NTR} \times 100\% , \quad (23)$$

onde *NTC* é o número de tarefas concluídas e *NTR* é o número de tentativas realizadas.

Outra métrica utilizada no experimento *online* foi o tempo necessário para a transferência de cada objeto do ponto A para o ponto B.

## 6 RESULTADOS E DISCUSSÃO

Este capítulo apresenta os resultados e discussões dos ensaios propostos na metodologia. Para isso, dividimos em duas seções: a primeira seção (6.1) apresenta os resultados e análises dos sistemas de classificação utilizando os bancos de dados Ninapro e a segunda seção (6.2) mostra os resultados e análises dos sistemas *offline* e *online* utilizando o banco de dados KidoPro, desenvolvido nesta tese.

### 6.1 BANCOS DE DADOS NINAPRO


Após a implementação de todas as etapas para reconhecimento de movimentos através de sinais EMG e aprendizado de máquina, os desempenhos dos classificadores implementados foram comparados entre si e com a literatura existente utilizando os mesmos bancos de dados (NinaPro DB2 e DB3). Para estes mesmos bancos de dados foram avaliados os impactos na taxa de acerto dos classificadores com a incorporação/alteração das configurações dos seguintes recursos:

- Configurações de janelamento;
- Mudança do número de canais EMG;
- Uso de acelerometria e eletromiografia simultaneamente;
- Redução da dimensionalidade das *features*.

#### 6.1.1 Classificadores


Para este primeiro ensaio, consideramos para os quatro classificadores (CNN, MLP, RF e RNN) a mesma configuração de janelamento: tamanho da janela de 200 ms e sobreposição (incremento) de 100 ms. Os resultados dos classificadores, considerando 12 movimentos/gestos de mão, são apresentados nos gráficos 4 e 5 para os bancos de dados DB2 (sujeitos não amputados) e DB3 (voluntários amputados) respectivamente.

Gráfico 4 - Acurácia dos classificadores considerando 12 classes e quatro classificadores: (a) acurácias (média) de cada voluntário do *dataset* DB2; (b) acurácias (média) dos classificadores considerando os dez voluntários do banco de dados DB2.



Fonte: elaborado pelo autor (2021).

Gráfico 5 - Acurácia dos classificadores considerando 12 classes e quatro classificadores: (a) acurácias (média) de cada voluntário do *dataset* DB3; (b) acurácias (média) dos classificadores CNN considerando os dez voluntários do banco de dados DB3.



Fonte: elaborado pelo autor (2021).

Comparando os resultados dos diferentes classificadores para os dois bancos de dados, observa-se um desempenho inferior na taxa de acerto dos movimentos dos voluntários amputados (DB3), com decremento de 18% a 23% em relação aos valores de acurácia para voluntários não amputados (DB2).



Para o banco de dados DB2 e com o ensaio de 12 movimentos, o sétimo voluntário apresentou a menor taxa de acerto em três (CNN, MLP e RF) dos quatro classificadores. Já o voluntário 9 apresentou a melhor acurácia média em três (CNN, MLP e RNN) dos quatro classificadores testados. Com relação ao desempenho dos classificadores, o algoritmo RF apresentou a maior taxa de acerto média (78,99%); entretanto, neste ensaio, as diferenças não foram significativas ( $p > 0,05$ ) em relação ao classificador MLP que obteve acurácia média de 78,51%. Já o classificador RNN obteve a menor taxa de acerto média com valor de 53,33%.

No ensaio com sujeitos amputados (banco de dados DB3) não foram considerados no cálculo da acurácia média de cada classificador implementado os resultados de desempenho do sétimo voluntário, por ele apresentar baixa acurácia de classificação (menor que 10% na acurácia ponderada) em todos os testes (ZHAI *et al.*, 2017 fazem a mesma consideração em suas análises). Com exceção dos resultados obtidos pelo classificador CNN, o décimo voluntário apresentou as menores taxas de acerto. Os maiores valores de acurácia foram obtidos pelos sujeitos 8 e 11 nos quatro classificadores implementados. Em relação ao desempenho de cada classificador, o algoritmo RF apresentou a maior taxa de acerto média (61,65%), entretanto, neste ensaio, as diferenças não foram significativas ( $p > 0,05$ ) em relação ao comparador MLP que obteve acurácia média de 60,57%. Já o classificador RNN obteve a menor taxa de acerto média com valor de 39,77%. A tabela 7 resume o desempenho de cada classificador aplicado aos bancos de dados NinaPro DB2 (voluntários não amputados) e DB3 (voluntários amputados).


Tabela 7 - Acurácia média e desvio-padrão dos classificadores implementados

<b>Classificador</b>	<b>Database DB2</b>	<b>Database DB3</b>
CNN	72,50 ± 7,94	49,24 ± 9,39
MLP	78,51 ± 5,02	60,57 ± 10,09
RF	78,99 ± 5,01	61,65 ± 8,97
RNN	53,33 ± 7,69	39,77 ± 10,49

Fonte: elaborado pelo autor (2021).


Os dois melhores sistemas de classificação implementados nesta tese (MLP e RF) foram comparados com a literatura existente. Nesta comparação, considerou-se trabalhos que também utilizaram os bancos de dados de sinais EMG NinaPro DB2 e DB3. O número de movimentos treinados e testados pelos classificadores MLP e RF implementados nesta tese foi ajustado para 50, valor de referência dos trabalhos comparados, obtendo assim, uma comparação mais apropriada. Os resultados dos classificadores MLP e RF, considerando estes 50 movimentos/gestos de mão, são apresentados no gráfico 6 para o banco de dados DB2 (não amputados) e no gráfico 7 para o banco de dados de voluntários amputados (DB3). No APÊNDICE E apresentamos as matrizes de confusão para o melhor e pior cenário dos dois classificadores implementados.

Gráfico 6 - Acurácia dos classificadores considerando 50 classes da base de dados DB2: (a) acurácias (médias) ponderada e geral de cada voluntário utilizando os classificadores MLP e RF; (b) acurácia (média) ponderada dos classificadores MLP e RF considerando os dez voluntários; (c) acurácia (média) geral dos classificadores MLP e RF considerando os dez voluntários.



Fonte: elaborado pelo autor (2021).

Gráfico 7 - Acurácia dos classificadores considerando 50 classes da base de dados DB3: (a) acurácias (médias) ponderada e geral de cada voluntário utilizando os classificadores MLP e RF; (b) acurácia (média) ponderada dos classificadores MLP e RF considerando os onze voluntários; (c) acurácia (média) geral dos classificadores MLP e RF considerando os onze voluntários.



Fonte: elaborado pelo autor (2021).

A análise comparativa com a literatura existente considerou que todos os classificadores utilizaram as mesmas amostras dos movimentos (ou seja, as repetições 1, 3, 4 e 6 dos movimentos para treinamento e as repetições 2 e 5 de todos os movimentos para os testes nos bancos de dados DB2 e DB3). Foram selecionados os trabalhos de Ding *et al.* (2018), Geng *et al.* (2018), Zhai e colaboradores (2017), Atzori *et al.* (2016) e Gijsberts *et al.* (2014) elencado o(s) melhor(es) classificador(es) de cada estudo conforme mostrado na tabela 8.

A acurácia média de nosso melhor classificador (neste caso, o classificador RF), considerando todos os 50 tipos de movimentos (classe de repouso incluída) para o banco de dados DB2, foi de 75,88%, um pouco menor que o melhor resultado (78,86%) apresentado por Ding e colaboradores (2018) com a Rede Neural Convolucional. O trabalho apresentado por Gijsberts *et al.* (2014), embora também tenha obtido um resultado superior, utilizou 40 movimentos para classificação do sistema.

Tabela 8 - Acurácias médias para diferentes trabalhos, *dataset* DB2 e DB3


Autor(es)	Janelamento (ms)	Database	Classificador	Acurácia média (%)
Ding <i>et al.</i> (2018)	100 + 10	DB2	CNN	78,86
Geng <i>et al.</i> (2018)	200	DB2	CNN	77,80
Zhai <i>et al.</i> (2017)	200 + 100	DB2	CNN	78,71
			SVM	77,44
		DB3	CNN	~57,0
			SVM	~55,0
Atzori <i>et al.</i> (2016)	200	DB2	RF	75,27
		DB3	SVM	46,27
Gijsberts <i>et al.</i> (2014)	400 + 10	DB2	KRLS	77,48
Este trabalho	200 + 100	DB2	RF	75,88
			MLP	74,04
		DB3	RF	56,08
			MLP	53,06

Fonte: elaborado pelo autor (2021).

Para o banco de dados DB3 com 50 classes, o melhor resultado desta tese também foi com o classificador RF que obteve uma acurácia média de classificação de 56,08%, desconsiderando o sujeito 7 (com o sétimo voluntário a taxa de acerto foi de 53,61%), valor superior ao trabalho de Atzori *et al.* (2016) que apresentou uma acurácia de 46,27% e ligeiramente menor que o sistema de reconhecimento de Zhai *et al.* (2017) que apresentou aproximadamente 57,0% (este estudo não considerou o sétimo voluntário) para o classificador CNN.

Outro ponto observável da classificação para as diferentes arquiteturas implementadas e testadas nos dois bancos de dados (DB2 e DB3) é a diferença significativa entre as acurácias geral e ponderada. Estas diferenças se devem a classe repouso que representa quase 60% de todas as amostras, fazendo com que os classificadores sejam tendenciosos ao realizar a classificação dos movimentos, gerando um viés (*bias*) de classificação (ATZORI *et al.*, 2014a). Para o classificador RF, isto também pode ser visto através das distribuições dos movimentos apresentados nos histogramas para os bancos de dados DB2 e DB3 (gráfico 8), mostrando uma única classe com desempenho muito alto e que corresponde à postura de repouso.


Gráfico 8 - Histograma da acurácia de classificação sobre movimentos (classificador RF): (a) banco de dados DB2; (b) banco de dados DB3.



Fonte: elaborado pelo autor (2021).

Para o classificador MLP, a classe repouso também apresenta a maior taxa de acerto em relação às demais, mas o MLP tende a ser menos tendencioso que o classificador RF (gráfico 9).

Gráfico 9 - Histograma da acurácia de classificação sobre movimentos (classificador MLP): (a) banco de dados DB2; (b) banco de dados DB3.



Fonte: elaborado pelo autor (2021).


Pode-se verificar nas matrizes de confusão de cada classificador para o melhor e pior cenário (figuras 64 a 67 do APENDICE E) que a maioria dos segmentos de movimentos foi classificada incorretamente como classe zero, sendo estes segmentos mostrados como FN (Falso negativo).

Para minimizar o viés (*bias*) no cálculo da acurácia, Zhai *et al.* (2017) balancearam o número de amostras de todas as classes, incluindo a posição de repouso. Já outros trabalhos não utilizaram a classe repouso nos sistemas de classificação, como no trabalho de Zhang *et al.* (2019), que aplicou uma função de detecção de atividade muscular, removendo a posição relaxada do conjunto de dados. Nesta tese, a partir do próximo experimento para os bancos de dados NinaPro DB2 e DB3, foi realizado o balanceamento da classe repouso com o objetivo de reduzir o viés (*bias*) de classificação. Com este método, a taxa de acerto dos movimentos foi chamada de apenas acurácia.

### 6.1.2 Efeito da Segmentação


Neste experimento a acurácia de classificação foi examinada levando-se em consideração a alteração da segmentação dos dados. Foram testadas as seguintes configurações de tamanho de segmento e incremento: 100 ms/50 ms (200 amostras/100 amostras), 200 ms/100 ms (400 amostras/200 amostras) e 250 ms/125 ms (500 amostras/250 amostras). Os resultados dos classificadores MLP e RF são apresentados no gráfico 10 para o banco de dados DB2 (não amputados) e no gráfico 11 para o banco de dados de voluntários amputados (DB3).

Gráfico 10 - Acurácia dos classificadores para diferentes configurações de segmentação na base de dados DB2: (a) acurácias (média) de cada voluntário utilizando o classificador MLP; (b) acurácia média do classificador MLP considerando os dez voluntários; (c) acurácias (média) de cada voluntário aplicando o classificador RF; (d) acurácia média do classificador RF considerando os dez voluntários.



Fonte: elaborado pelo autor (2021).

Gráfico 11 - Acurácia dos classificadores para diferentes configurações de segmentação na base de dados DB3: (a) acurácias (média) de cada voluntário utilizando o classificador MLP; (b) acurácia média do classificador MLP considerando os dez voluntários; (c) acurácias (média) de cada voluntário aplicando o classificador RF; (d) acurácia média do classificador RF considerando os dez voluntários.



Fonte: elaborado pelo autor (2021).

Os resultados das acurácias médias dos classificadores mostraram que a taxa de acerto aumenta com o aumento do comprimento do segmento. Isso ocorre porque o segmento mais alargado pode fornecer informações adicionais e produzir uma variação menor nos cálculos das *features*. Resultados similares foram apresentados nos estudos de Phinyomark *et al.* (2013) e Atzori e colaboradores (2015) apontando, em ambos os trabalhos, o incremento das taxas de acerto de classificação para comprimentos de janelas maiores.

Entretanto, neste ensaio, as diferenças entre as configurações 200 ms/100 ms e 250 ms/125 ms não foram significativas ( $p > 0,05$ ) nos dois classificadores aplicados aos dois bancos de dados (DB2 e DB3). Desta forma, para os demais ensaios foi adotado o tamanho de janela de segmentação de 200 ms e incremento de janela (sobreposição) de 100 ms. Também não ocorreram diferenças significativas ( $p > 0,05$ ) entre os classificadores, embora o classificador RF tenha obtido valor ligeiramente maior para todas as configurações de janelamento aplicadas nos dois bancos de dados, exceto na configuração 250 ms/125 ms, onde o classificador MLP atingiu taxa de acerto média de  $(79,15 \pm 4,52)\%$ .

Farrel (2011) acredita que a busca por melhores configurações de janelamento pouco contribuem para o desempenho da prótese durante seu uso real, entretanto diferentes conjuntos de recursos (considerando também o janelamento) e aplicados a diferentes classificadores, podem desempenhar um papel relevante no incremento da *performance* de execução do sistema protético. Neste contexto, os três próximos ensaios avaliaram o desempenho dos classificadores mediante alteração de parâmetros e/ou inserção de recursos.


### 6.1.3 Número de canais EMG

Uma forma de otimizar os custos econômicos de hardware e de processamento de dados para os sistemas controlados por EMG é a minimização do vetor de *features*. Mas isto pode trazer como consequência uma redução da acurácia de classificação (RAURALE *et al.*, 2020). Desta forma, avaliar um conjunto mínimo de canais e/ou *features* que mantém níveis aceitáveis de desempenho passa a ser mais um ponto no desenvolvimento de sistemas de reconhecimento de padrão. Diferentes estratégias são aplicadas para esta temática, como o método para seleção de canais apresentado no estudo de Yao *et al.* (2020) que a partir de uma grande quantidade de canais EMG, determina, em forma de conjuntos, quais os canais mais informativos. Embora tenhamos nesta tese, um número pequeno de canais EMG, foi avaliado o efeito da redução do seu valor na predição dos movimentos.



Os resultados do conjunto de cinco combinações de eletrodos, variando de 6 a 12 canais, são apresentados no gráfico 12 para os bancos de dados de voluntários não amputados (NinaPro DB2).

Gráfico 12 - Resultado da classificação para cinco conjuntos de eletrodos (banco de dados DB2)



Conjuntos: A (4 eletrodos), B (6 eletrodos), C (8 eletrodos), D (10 eletrodos), E (12 eletrodos)

Fonte: elaborado pelo autor (2021).

Nos gráficos anteriores e para os dois classificadores aplicados, podemos observar a dependência entre a taxa de acerto e o número de canais utilizados nos ensaios. Para o banco de dados DB2 e o classificador MLP, o conjunto A (4 canais) apresentou acurácia média de  $(61,25 \pm 8,11)\%$  enquanto o conjunto E (12 canais de sinais EMG) obteve taxa de acerto média de  $(78,51 \pm 5,02)\%$  ocorrendo diferenças significativas entre todos os conjuntos. Para o classificador RF, o conjunto E apresentou a maior taxa média de acertos com  $(78,99 \pm 5,01)\%$  e o conjunto A acurácia média de classificação de  $(62,80 \pm 7,97)\%$  e não ocorreram diferenças significativas ( $p > 0,05$ ) apenas entre os conjuntos D (10 canais) e E (12 canais) obtendo um aumento modesto de 1,08%.

Ainda sobre a dependência do número de eletrodos EMG na classificação dos movimentos, calculamos o incremento de erros (em percentual) de acordo com a redução do número de canais e resumimos os resultados na tabela 9, considerando o conjunto E como referência.

Tabela 9 - Contribuição de cada conjunto de canal - *Dataset* DB2

Conjunto	Ao redor do braço	Bíceps e tríceps	Flexão e extensão dos dedos	Total de canais EMG	Incremento de erros (%)	
					MLP	RF
E	8	2	2	12	0*	0*
D	8	2	-	10	6,48	5,15
C	4	2	2	8	19,83	22,33
B	2	2	2	6	34,19	36,86
A	-	2	2	4	69,35	68,44


Nota: \*considerando o conjunto E como referência

Fonte: elaborado pelo autor (2021).

A tabela mostra uma tendência semelhante nos dois classificadores com um incremento de erros de classificação de mais de 30% quando reduzimos pela metade o número de canais EMG. Estes resultados diferem dos estudos apresentados por Farrel e Weir (2008) e Young *et al.* (2012) que afirmaram que mais de quatro (ou seis para o segundo trabalho) canais EMG não fornecem nenhum benefício significativo para reduzir o erro de classificação em sistemas de reconhecimento de até 12 movimentos/gestos de mão, mas fortalecem e corroboram com os trabalhos de Young *et al.* (2013) e Raurale e colaboradores (2020) que apresentaram em seus resultados um aumento das taxas de acerto para sistemas classificadores com mais de quatro canais EMG.

O ensaio também foi realizado para o banco de dados de voluntários amputados (NinaPro DB3) e os resultados dos dois classificadores aplicados são apresentados no gráfico 13.

Gráfico 13 - Resultado da classificação para cinco conjuntos de eletrodos (banco de dados DB3)



Conjuntos: A (4 eletrodos), B (6 eletrodos), C (8 eletrodos), D (10 eletrodos), E (12 eletrodos)

Fonte: elaborado pelo autor (2021).

No gráfico 13 e para os dois classificadores aplicados, podemos observar também o aumento da taxa de acerto com o aumento do número de canais EMG. O classificador MLP, apresentou acurácia média de classificação de  $(45,61 \pm 13,19)\%$  para o conjunto A (4 canais) enquanto o conjunto E (12 canais de sinais EMG) obteve taxa de acerto média de  $(60,57 \pm 10,09)\%$  ocorrendo diferenças não significativas apenas entre os conjunto D e E. Para o classificador RF, o conjunto E apresentou a maior taxa média de acertos com  $(61,65 \pm 8,97)\%$  e o conjunto A acurácia média de  $(48,44 \pm 12,90)\%$  e não ocorreram diferenças significativas ( $p > 0,05$ ) apenas entre os conjuntos de 12 e 10 canais e entre os conjuntos C e D.

E a tabela 10 apresenta um resumo da contribuição de cada conjunto no incremento do erro de classificação com o incremento dos erros para cada classificador neste *dataset*, considerando novamente o conjunto E como referência.

Tabela 10 - Contribuição de cada conjunto de canal - *Dataset* DB3

Conjunto	Ao redor do braço	Bíceps e tríceps	Flexão e extensão dos dedos	Total de canais EMG	Incremento de erros (%)	
					MLP	RF
E	8	2	2	12	0*	0*
D	8	2	-	10	1,69	2,49
C	4	2	2	8	10,81	8,55
B	2	2	2	6	20,84	18,12
A	-	2	2	4	37,94	34,46

Nota: \*considerando o conjunto E como referência

Fonte: elaborado pelo autor (2021).

Com base nos resultados experimentais, pode ser observada na tabela anterior uma tendência semelhante nos dois classificadores com um incremento de erro de mais de 30% quando reduzimos de doze para quatro canais EMG.


Uma última análise realizada foi uma comparação entre conjuntos com o mesmo número de canais. Observou-se taxas de acerto diferentes entre estes grupos (exemplo, o conjunto F formado pelos oito eletrodos ao redor do braço possui acurácias médias menores que o conjunto C, para todos os classificadores e *datasets* aplicados), o que evidencia que determinados conjuntos carregam mais informações do que outros com a mesma quantidade de eletrodos confirmando os resultados obtidos por Yao *et al.* (2020).

#### 6.1.4 Combinando eletromiografia com acelerometria

Como descrito na seção anterior, em aplicações da vida real é essencial no projeto de sistemas de reconhecimento de gestos/movimentos de mão a avaliação de um conjunto mínimo de sensores que mantém níveis aceitáveis de desempenho. Neste sentido, investigamos a contribuição de outro(s) sensor(es) na melhoria das taxas de acerto. Combinamos sensores EMG com acelerômetros em um classificador multimodal e avaliamos o incremento de *performance* nas taxas de acerto dos classificadores implementados. Para ilustrar este ponto, a figura 43 apresenta os resultados em um trecho (janela) de três movimentos/gestos de mão

realizados por um voluntário, onde visualizamos em (a) os sinais EMG de quatro eletrodos adquiridos, em (b) os sinais de acelerometria de canais, em (c) o resultado da classificação com apenas sinais EMG e em (d) o resultado da predição através do classificador multimodal utilizando sinais eletromiográficos em combinação com os sinais dos acelerômetros.

Figura 43 - (a) Aquisição de sinais de 4 canais EMG; (b) Aquisição de sinais de 4 canais ACC; (c) Classificação dos movimentos de mão utilizando apenas sinais EMG; (d) Classificação combinando eletromiografia com acelerometria. Nota: banco de dados DB3, classificador RF, voluntário 3, classificador RF.




Fonte: elaborado pelo autor (2021).

Neste trecho exemplificado, pode-se observar na figura 47(d) em comparação com a figura 47(c) e a partir do tempo 8 s (classe 1) a correta classificação dos dois movimentos seguintes e redução substancial dos erros de classificação, com exceção dos intervalos de tempo de 7,4 s a 7,6 s (classe 1) e 11,9 s a 12,1 s (transição entre as classes 1 e 2) e no início da sessão (intervalo de 0 s a 0,3 s).

Em termos numéricos, os resultados dos classificadores MLP e RF para reconhecimento de 12 movimentos de voluntários não amputados (banco de dados DB2) são mostrados no gráfico 14: (a) acurácia média de cada voluntário utilizando o classificador MLP; (b) acurácia média do classificador MLP considerando os dez voluntários; (c) acurácia média de cada voluntário aplicando o classificador RF; (d) acurácia média do classificador RF considerando os dez voluntários.

Gráfico 14 - Combinando eletromiografia com acelerometria (banco de dados DB2): (a) acurácia média de cada sujeito para o classificador MLP; (b) acurácia média para o classificador MLP; (c) acurácia média de cada sujeito para o classificador RF; (d) acurácia média para o classificador RF.




Fonte: elaborado pelo autor (2021).

Considerando o banco de dados de voluntários não amputados (DB2), é possível observarmos o incremento do desempenho de classificação para todos os voluntários (para nono voluntário, com o classificador RF, a acurácia média foi acima de 95%). As taxas de acerto médias, considerando todos os voluntários, foram de

(90,13 ± 3,08)% para o classificador RF e (87,55 ± 2,63)% para o classificador MLP, alcançando, respectivamente, uma melhoria significativa ( $p < 0,001$ ) de 11% e 9% com relação à classificação com apenas sinais EMG.

Resultados similares (aumento das taxas de acerto) foram encontrados para o banco de dados de voluntários amputados (DB3) e são apresentados no gráfico 15: (a) acurácia média de cada voluntário utilizando o classificador MLP; (b) acurácia média do classificador MLP considerando os dez voluntários; (c) acurácia média de cada voluntário aplicando o classificador RF; (d) acurácia média do classificador RF considerando os dez voluntários.

Gráfico 15 - Combinando eletromiografia com acelerometria (banco de dados DB3): (a) acurácia média de cada sujeito para o classificador MLP; (b) acurácia média para o classificador MLP; (c) acurácia média de cada sujeito para o classificador RF; (d) acurácia média para o classificador RF.



Fonte: elaborado pelo autor (2021).

Para o banco de dados DB3, também é possível observarmos o incremento do desempenho de classificação para todos os voluntários, onde o melhor resultado foi obtido pelo oitavo voluntário com acurácia média acima de 93% para os dois classificadores. O pior resultado foi atribuído ao décimo voluntário (63,1% para o classificador MLP e 69,4% para o classificador RF) que já havia apresentado o pior resultado na classificação utilizando apenas sinais EMG. No geral, o classificador RF obteve taxa média de acerto de  $(83,77 \pm 6,77)\%$  e o classificador MLP acurácia média de  $(79,41 \pm 8,36)\%$ , incrementando os desempenhos em 22,12% e 19,46% respectivamente.

Comparamos nossos classificadores com a literatura existente (tabela 14). Nesta tabela, consideramos a utilização de sinais de voluntários não amputados. Embora os sistemas de classificação possuam diferentes números de classes e sensores, cada trabalho também explorou a comparação do uso de apenas sensores EMG e o incremento da taxa de acerto com a inserção dos sensores inerciais.

Tabela 11 - Acurácia média para diferentes trabalhos combinando sensores EMG e ACC e voluntários não amputados

<b>Autor(es)</b>	<b>Número de classes</b>	<b>Sensores</b>	<b>Classificador</b>	<b>Acurácia média (%)</b>
Krasoulis <i>et al.</i> (2017)	40	12 EMG e 36 ACC	LDA	76,00
Lv <i>et al.</i> (2017)	5	8 EMG e 8 ACC	RDA	85,77
Khushaba <i>et al.</i> (2016)	6	6 EMG e 3 ACC	SVM	90,00 ~ 91,00
Atzori <i>et al.</i> (2014b)	40	12 EMG e 36 ACC	KRLS	82,49
Fougner <i>et al.</i> (2011)	8	8 EMG e 6 ACC	LDA	95,00 ~ 96,00
Este trabalho	12	12 EMG e 36 ACC	RF	90,13
			MLP	87,55

Fonte: elaborado pelo autor (2021).

Embora o trabalho de Krasoulis *et al.* (2017) tenha apresentado menor valor em relação as demais literaturas, os autores ainda exploraram a utilização de outros sensores como giroscópios (GIR) e magnetômetros (MAG), obtendo acurácia média, para voluntários não amputados, no valor de 82,7% e observaram um acréscimo no



desempenho de 22,6% quando comparado aos seus resultados com apenas sensores EMG. Com estes mesmos sensores (EMG, ACC, GIR e MAG), Kyranou *et al.* (2016) também investigaram se o controle protético mioelétrico poderia se beneficiar com a inclusão destes elementos. Utilizando o método LDA como classificador, eles obtiveram uma acurácia média de 94,5% para seis classes.


Para dados de indivíduos com amputação de mão, Krasoulis *et al.* (2017) apresentaram um experimento com dois amputados e 40 movimentos/gestos de mão a serem classificados utilizando sinais EMG e ACC, obtendo uma acurácia média de 64,6%. Para a utilização combinada de acelerômetros, giroscópios e magnetômetros o valor da taxa de acerto foi para 77,8%, incrementando a *performance* em 31,7% em relação aos resultados com apenas sinais EMG. O trabalho de Atzori e colaboradores (2014b) analisou a classificação de 40 movimentos de mão em cinco amputados usando dados de EMG e acelerometria aplicando os classificadores LDA, kNN e KRLS. O melhor resultado obtido foi do classificador KRLS com taxa de acerto pouco abaixo de 80%. Nesta tese, além dos resultados dos classificadores para 12 movimentos, que obtiveram acertos médios de 83,77% para o classificador RF e 79,41% para o classificador MLP, estendemos o experimento para 24 classes no banco de dados NinaPro DB3 obtendo taxas médias de acerto de  $(81,28 \pm 6,72)\%$  para o classificador RF (acrécimo de acurácia de 25,37%) e  $(76,32 \pm 7,41)\%$  para o classificador MLP (acrécimo de desempenho da taxa de acerto de 21,28%).

Essas comparações, embora com números de sensores e/ou número de classes diferentes, mostraram resultados de desempenho dos classificadores implementados compatíveis com os melhores resultados obtidos na literatura existente, demonstrando também o benefício de integrar outros sensores, como o acelerômetro, em um classificador multimodal com o fornecimento de informações complementares que permitiram a redução dos erros de classificação nos sistemas de reconhecimento de gestos de mão.

### 6.1.5 Redução da dimensionalidade

Neste ensaio, a redução da dimensionalidade (ou extração de atributos) do vetor de *features* foi realizada através dos métodos LDA e PCA com o objetivo de incrementar a taxa de acerto de classificação. O desempenho destas projeções com classificadores MLP e RF para bancos de dados DB3 são apresentados no gráfico 16. O ensaio foi realizado com o vetor de *features* da seção 6.1.4 (dados de sinais EMG e ACC, sendo chamado na figura de resultado padrão) com 12 movimentos a serem classificados.

Gráfico 16 - Resultados dos diferentes métodos de redução da dimensionalidade em conjunto com os classificadores MLP e RF (banco de dados DB3).



Fonte: elaborado pelo autor (2021).

Considerando as mesmas dimensões de projeção para os métodos LDA e PCA e em comparação com o ensaio anterior (padrão), observamos um incremento significativo ( $p < 0,05$ ) na taxa de acerto média com o método LDA. Combinando a projeção LDA e o classificador de RF, a acurácia média foi para 85,44% (anteriormente com 83,77%). O método LDA em combinação com o classificador MLP alcançou uma taxa de acerto média de 82,40% (anteriormente com 79,41%). Isso indica que o conjunto LDA mais classificador pode reduzir a redundância de dados ACC e EMG; e é benéfico para o sistema de reconhecimento de gestos de mão.

No entanto, para os classificadores com projeção de recurso PCA, as acurácias médias foram inferiores a 75%. Isso sugere que a abordagem perdeu algumas informações úteis dos sinais EMG e/ou ACC. Ainda para a combinação PCA com os classificadores MLP ou RF, aumentando a dimensão do método ocorreu o incremento da taxa de acerto; para dimensão  $k = 40$  a acurácia média foi de  $(78,08 \pm 9,27)\%$  para o classificador MLP e de  $(76,62 \pm 6,99)\%$  para o classificador RF, mas estes valores não incrementaram a taxa de acerto em relação aos sistemas de classificação que não aplicavam os métodos de redução da dimensionalidade.

Aumentando o número de classes para vinte e quatro, a combinação LDA com RF também apresentou aumento no desempenho ( $p < 0,05$ ), de 81,28% (sistema sem o método de redução da dimensionalidade) para 83,67% e a projeção LDA com o classificador MLP obteve uma taxa de acerto de 80,24%, valor superior e significativo ( $p < 0,05$ ) ao sistema de classificação que não aplicava o método de redução da dimensionalidade (76,32%). Foi observado novamente que o método PCA em combinação com os classificadores não apresentou melhorias das taxas de acerto em relação aos sistemas de classificação que não utilizaram métodos de projeção de *features*.

## 6.2 BANCO DE DADOS KIDOPRO

Após a aquisição dos sinais EMG de voluntários locais, a rotulagem das classes e formatação deste novo *dataset* (descritos na seção 5.1.2), ensaios foram realizados contemplando os seguintes itens:


- Configurações de janelamento;
- Classificação *offline*;
- Tempo de execução das etapas de pré-processamento, cálculo de *features* e predição para o reconhecimento de gestos de mão;
- Preensão e deslocamento de objetos.

Estes dois últimos itens foram analisados na plataforma de prototipagem rápida e de forma *Online*, realizando a aquisição *real-time* dos sinais EMG.

### 6.2.1 Segmentação do banco de dados KidoPro


Para o banco de dados de voluntários locais (KidoPro), também foi realizado um experimento para avaliação da etapa de segmentação dos dados EMG. O método utilizado foi também de segmentação por janelas deslizantes com sobreposição e três diferentes tamanhos e incrementos da janela foram avaliados: 100 ms/50 ms, 200 ms/100 ms e 250ms/125 ms. Os resultados de desempenho dos classificadores MLP e RF são apresentados nos gráficos 17 e 18 respectivamente.

Gráfico 17 - Acurácia dos classificadores para diferentes configurações de segmentação na base de dados KidoPro: (a) acurácias (média) ponderada e geral de cada voluntário utilizando o classificador MLP; (b) acurácia (média) ponderada do classificador MLP considerando os cinco voluntários; (c) acurácia (média) geral do classificador MLP considerando os cinco voluntários.



Fonte: elaborado pelo autor (2021).

Gráfico 18 - Acurácia dos classificadores para diferentes configurações de segmentação na base de dados KidoPro: (a) acurácias (média) ponderada e geral de cada voluntário utilizando o classificador RF; (b) acurácia (média) ponderada do classificador RF considerando os cinco voluntários; (c) acurácia (média) geral do classificador RF considerando os cinco voluntários.



Fonte: elaborado pelo autor (2021).


No ensaio utilizando os dados EMG dos voluntários locais, observamos também o aumento da taxa de acerto de classificação com o aumento da janela deslizante. Para os dois classificadores aplicados, todos os voluntários atingiram taxas de acerto média acima de 95% a partir da configuração 200 ms/100 ms. As diferenças entre as configurações 200 ms/100 ms e 250 ms/125 ms não foram significativas ( $p > 0,05$ ) nos dois classificadores. Também não ocorreram diferenças significativas ( $p > 0,05$ ) entre os classificadores, embora o classificador MLP tenha obtido valor ligeiramente maior para as três configurações de comprimento de segmento. Na configuração de 200 ms/100 ms o classificador MLP atingiu acurácia média geral de  $(96,30 \pm 0,79)\%$  e o classificador RF obteve taxa de acerto geral de  $(96,26 \pm 0,81)\%$ .

Outra observação é que utilizando o mesmo protocolo de posicionamento, o mesmo ensaio dos movimentos e as mesmas configurações para aquisição dos sinais EMG, os diferentes voluntários tendem a apresentar características bioelétricas diferentes e que influenciaram nas classificações dos movimentos. De

acordo com Atzori e colaboradores (2015), indivíduos com IMC (Índice de Massa Corporal) menores tendem a atingir taxas de acertos (acurácias) mais altas. No experimento com voluntários locais, o terceiro voluntário (com maior IMC) obteve as menores acurácias gerais e ponderadas na maioria dos ensaios com diferentes janelamentos enquanto o segundo e quarto voluntários (menores IMC dos ensaios) atingiram as maiores taxas de acerto ponderada e geral em todos os experimentos com diferentes configurações de janelamento, corroborando com o estudo de Atzori *et al.* (2015), e indicando que indivíduos com tecido adiposo mais espesso, tendem a diminuir a amplitude do sinal EMG e a relação sinal/ruído, pois a camada adiposa atua como um isolante. Este mesmo comportamento também é observado no desvio padrão das acurácias geral e ponderada, onde o terceiro voluntário obteve os maiores valores e o quarto voluntário apresentou os menores resultados na maioria dos ensaios com diferentes configurações de janelamento.

Com relação à classificação de cada movimento/gesto de mão, as figuras 44 e 45 apresentam as matrizes de confusão de cada classificador para o melhor e pior cenário. É possível observar para o terceiro voluntário que a maioria dos erros de classificação ocorreu entre as classes.

Figura 44 - Matrizes de confusão do classificador MLP:  
(a) melhor cenário (voluntário 4); (b) pior cenário (voluntário 3)




(a) Melhor cenário (voluntário 4)

(a) Pior cenário (voluntário 3)

Fonte: elaborado pelo autor (2021).

Figura 45 - Matrizes de confusão do classificador RF:  
 (a) melhor cenário (voluntário 4); (b) pior cenário (voluntário 3)



(a) Melhor cenário (voluntário 4)

(b) Pior cenário (voluntário 3)

Fonte: elaborado pelo autor (2021).

Após os testes de janelamento, o método de redução da dimensionalidade foi implementado utilizando a técnica LDA. O experimento foi realizado com dimensionalidade  $k = 10$  e os resultados para as duas combinações (LDA + MLP e LDA + RF) não apresentaram aumento da taxa de acerto.

### 6.2.2 Comparação com a literatura existente

O classificador MLP aplicado ao banco de dados KidoPro foi comparado com a literatura existente. Nesta comparação, consideramos trabalhos que utilizaram sistemas de classificação entre seis e onze classes. Um resumo é apresentado na tabela 12 com o desempenho de cada trabalho e ainda informações do classificador utilizado, janelamento e número de classes testadas.

Tabela 12 - Acurácia média dos trabalhos com bancos de dados próprios

<b>Autor(es)</b>	<b>Número de classes</b>	<b>Classificador</b>	<b>Janelamento (ms)</b>	<b>Acurácia (%)</b>
Abbaspour <i>et al.</i> (2020)	11	MLE	200/100	97,43
Rehman <i>et al.</i> (2017)	11	AE	200/28,5	98,90
Na <i>et al.</i> (2019)	10	CNN	-	94,06
Raurale <i>et al.</i> (2020)	9	MLP	250/125	99,30
Sanchez-Velasco <i>et al.</i> (2020)	8	EAM	100	95,83
Ameri <i>et al.</i> (2018)	8	CNN	160/40	91,61
Yao <i>et al.</i> (2020)	7	LDA	256/64	94,42
Cene <i>et al.</i> (2018)	7	ELM	300/15	94,04
Motoche e Benalcázar (2018)	6	ANN	1000/100	90,70
Este trabalho	11	MLP	200/100	96,30

Fonte: elaborado pelo autor (2021).

Considerando 11 classes, o classificador MLP, aplicado no banco de dados de voluntários locais desta tese, obteve uma taxa de acerto de 96,30%, um pouco menor que o resultado (97,43%) apresentado por Abbaspour *et al.* (2020) com a utilização do método Estimativa da Máxima Verossimilhança (MLE - *Maximum Likelihood Estimation*) e superior a outros trabalhos com um menor número de movimentos classificados, como os trabalhos de Motoche e Benalcázar (2018) com acurácia média de 90,70% para seis classes e Sanchez-Velasco *et al.* (2020) com taxa de acerto média de 95,83% para oito movimentos classificados. O estudo de Raurale *et al.* (2020) apresentou os melhores resultados, com uma acurácia média de 99,30% para nove classes aplicando o classificador MLP, embora não tenha ficado claro no trabalho se o tamanho da janela foi de 250 ms ou 1280 ms, o que pode ter fornecido informações adicionais e ter produzido uma taxa de acerto maior no classificador.


Essas comparações, embora com diferentes recursos e configurações (frequência de amostragem e resolução dos sistemas de aquisição de sinais, tamanho da janela/sobreposição e/ou números de sensores EMG) e/ou número de classes diferentes, mostraram resultados de desempenho do sistema de classificação implementado nesta tese compatíveis com os melhores resultados obtidos na literatura existente.



### 6.2.3 Classificação inter-voluntários

O último experimento realizado no banco de dados KidoPro de forma *offline* diz respeito ao nível de personalização da prótese. Nesse caso, avaliamos em que medida uma prótese que utiliza um classificador já treinado pode prever os movimentos de um paciente/voluntário que ainda não teve seus sinais EMG utilizados para treinar esta prótese (esta análise é chamada de inter-usuário). O treinamento e validação do classificador foram realizados com dados de quatro voluntários e o teste com dados de outro voluntário local. O gráfico 19 apresenta os resultados das classificações intra-usuários e inter-usuários.

Gráfico 19 - Erro de classificação do classificador MLP para configurações intra-voluntários e inter-voluntários na base de dados KidoPro: (a) erros de classificação (média) de cada voluntário utilizando o classificador MLP; (b) erros de classificação (média) do classificador MLP considerando os cinco voluntários.



Fonte: elaborado pelo autor (2021).

Para a classificação intra-voluntários, os erros de classificação (ponderados) variaram de 3,8% a 6,2% (média de 4,8%) enquanto para o experimento inter-voluntários os resultados foram insatisfatórios para todos os sujeitos, com os erros de classificação de 68,4 % a 82,3% (média de 75,1%) e são comparáveis ao estudo apresentado por Atzori e colaboradores (2012) considerando o mesmo número de movimentos. Alguns fatores podem ser considerados para explicar essa variabilidade entre os voluntários, entre eles estão o diâmetro da fibra muscular, o número de fibras musculares, o número de unidades motoras ativas, a distância

entre a superfície da pele e as fibras musculares, a velocidade de condução, o fluxo sanguíneo no músculo, a distância entre eletrodos, a relação entre o tipo de fibra e sua localização e taxas de disparo das unidades motoras (KAMEN e CALDWELL, 1996). Duas abordagens podem ser seguidas a partir deste ponto: a primeira com o desenvolvimento de uma metodologia para criar modelos com maior sucesso para novos voluntários e a segunda, utilizada nesta tese, com a criação de um sistema de aquisição de sinais EMG de pacientes/usuários para treinar uma prótese, permitindo uma atividade de calibração individualizada.


Após os diferentes ensaios realizados de forma *offline*, o sistema de reconhecimento de gestos de mão foi implementado em uma plataforma de prototipação rápida, descrita na próxima seção juntamente com os resultados obtidos.

### 6.2.3 Sistema *Online*

A plataforma Raspberry Pi 3 B+ (ARM Cortex-A53 de 1,4 GHz) foi utilizada para os ensaios *online*. Todas as rotinas foram escritas em Python através da ferramenta Thonny IDE (*Integrated Development Environment* - Ambiente de Desenvolvimento Integrado) e a biblioteca Tensorflow Lite foi utilizada para o desenvolvimento do classificador MLP. Não foi necessária a compilação novamente do classificador na plataforma de prototipação rápida, pois no sistema *offline* sua estrutura e parâmetros foram salvos em arquivo *.json* (*JavaScript Object Notation*) e os pesos do modelo neural armazenados em um arquivo de formato *HDF5* (*.h5*), bastando carregar estes dois arquivos na plataforma. Essa abordagem, realizada individualmente, permitiu que todo o sistema treinado com os dados EMG de um voluntário fosse compilado e salvo em um computador *desktop*, bastando estes dois arquivos serem carregados em outro computador *desktop* ou em uma plataforma de prototipagem rápida.

O primeiro ensaio avaliou o desempenho de computação do sistema em tempo real. Foram medidos os tempos de pré-processamento, cálculo das *features* e predição do classificador utilizando as métricas: tempo médio de computação (e desvio padrão) e o tempo máximo de computação esperado dentro de um intervalo de confiança de 95%, assumindo dados de amostra com uma distribuição normal de Gauss. Os resultados são ilustrados no gráfico 20.

Gráfico 20 - Tempo de processamento das etapas de reconhecimento de gestos de mão do sistema *Online*



Fonte: elaborado pelo autor (2021).

O pré-processamento foi executado com um tempo médio de  $(1,61 \pm 0,91)$  ms, com 95% das amostras sendo computadas em 3,44 ms. A etapa de cálculo das *features* foi executada com um tempo de processamento de  $(4,73 \pm 0,63)$  ms com 95% das amostras sendo computadas em 5,84 ms. O valor de processamento médio para cada *feature* calculada é apresentado na tabela 13.

Tabela 13 - Tempo de processamento das *features*

<b>Feature</b>	<b>Média e desvio padrão (ms)</b>
RMS	$0,88 \pm 0,24$
MAV	$0,80 \pm 0,13$
WL	$1,33 \pm 0,40$
VAR	$1,71 \pm 0,33$

Fonte: elaborado pelo autor (2021).

O componente de predição foi executado com um tempo médio de  $(4,59 \pm 0,49)$  ms com 95% das amostras sendo processadas em 5,7 ms. O tempo total dessas três etapas do sistema (pré-processamento, cálculo das *features* e predição) foi executado com atraso médio de  $(10,28 \pm 1,81)$  ms e com 95% das amostras sendo processadas em 13,29 ms.

Em termos de comparação com a literatura existente, a implementação em tempo real desta tese apresentou resultados compatíveis com o estado da arte. Três trabalhos foram elencados e são apresentados a seguir.


O trabalho de Raurale *et al.* (2020) avaliou o efeito que a redução da complexidade do cálculo das *features* produziu sobre a capacidade de inferência em tempo real de dispositivos embarcados. Duas abordagens foram comparadas: a primeira no domínio do tempo, onde o sistema de reconhecimento de sinais analisado era composto das etapas de cálculo de *features* (sete funções no TD), redução da dimensionalidade (método LDA) e predição (classificador MLP) e a segunda, no domínio da frequência, onde a etapa de *features* utilizou a Transformada de Wavelet Packet (WPT - *Wavelet Packet Transform*) e as demais etapas já descritas na abordagem no TD. Duas implementações de cada abordagem foram analisadas. Primeiro, os tempos de processamento foram comparados utilizando um computador *desktop* obtendo, respectivamente, 60,34 ms e 567,22 ms para os domínios do tempo e da frequência. Na implementação em uma plataforma Raspberry Pi (ARM Cortex-A53), a abordagem no domínio da frequência executou as mesmas etapas no tempo de 219,452 ms enquanto a abordagem no domínio do tempo realizou o processamento em 9,75 ms.

Motoche e Benalcázar (2018) apresentaram em seu artigo um sistema *real-time* para reconhecimento de gestos de mão baseado em sinais EMG composto por cinco blocos: aquisição de dados, pré-processamento, cálculo de *features* utilizando cinco funções no domínio do tempo, classificação (rede neural de três camadas) e pós-processamento (votação majoritária). O sistema implementado apresentou um tempo de processamento total de 29,38 ms para a classificação de seis gestos de mão.

No estudo Abbaspour *et al.* (2020), os autores investigaram 44 características EMG (nos domínios do tempo e da frequência) e cinco combinações de tais *features* e testaram seis classificadores (kNN, LDA, DT, MLE, MLP e SVM) para decodificar 11 movimentos de membros superiores. A combinação de cinco *features* (variância, comprimento da forma de onda, coeficiente de correlação de Pearson e dois parâmetros de Hjorth, mobilidade e complexidade) com o classificador MLE (*Maximum Likelihood Estimation*) obteve a maior taxa de acerto com 97,43% e tempo de processamento na etapa de teste de 136 ms. A comparação com estes três trabalhos reforça o resultado obtido em nossa implementação *real-time*, pois superam ou se igualam aos tempos de processamento apresentados nestas literaturas.

O segundo ensaio apresentou a classificação dos movimentos/gestos de mão adquiridos de forma *real-time* de três voluntários (2, 3 e 4) do banco de dados kidoPro. Os dez movimentos foram mantidos por 3 s, seguidos do movimento de repouso, também mantido por um tempo de 3 s. No início do experimento, para se acostumar com o protocolo, os voluntários realizaram uma sequência de treinamento que envolveu a execução dos movimentos apresentados em uma imagem. Durante esta fase os voluntários também tinham *feedback* visual dos gestos realizados, ou seja, eles realizavam os movimentos e a plataforma informava (classificava) o gesto realizado, ajudando a alcançar e a caracterizar o movimento alvo. A trajetória real de movimentos e o histórico de decisão para cada gesto do voluntário 2 é apresentado na figura 46.

Figura 46 - Classificação *real-time* dos movimentos/gestos de mão do voluntário 2




Fonte: elaborado pelo autor (2021).

Entre os erros de classificação que ocorreram, é possível observarmos confusões entre os gestos de fechar a mão (classe 1) e de polegar (classe 2) pois representam entre si, movimentos com execuções parciais similares. Esta mesma observação pode ser vista nas classes 4, 9 e 10 (movimentos de pinça e de mandril). Ainda podemos verificar que não ocorreram erros de classificação no gesto de supinação (classe 7) e poucos erros nas classes 2 (polegar), 3 (mão aberta) e 5 (pega cilíndrica).

Para o ensaio com o voluntário 3, a figura 47 ilustra os resultados obtidos na execução dos onze gestos de mão.


Figura 47 - Classificação *real-time* dos movimentos/gestos de mão do voluntário 3



Fonte: elaborado pelo autor (2021).

Neste cenário, parte dos movimentos classificados de forma errada ocorreram nos gestos 5, 9 e 10 (movimentos de pinça e pega) que o classificador confundiu com o gesto 4 (movimento de pinça) por apresentar execuções parciais destes movimentos. É possível também observarmos erros de classificação dos gestos 3, 4, 7, 8 com o gesto 10 (gesto de mandril). Uma das hipóteses deste problema, além da confusão de classificação, pode ser o descolamento momentâneo de um dos eletrodos de superfície posicionados no membro do voluntário. Como fechamento deste ensaio, a figura 48 apresenta as trajetórias de gestos real e realizada do voluntário 4.

Figura 48 - Classificação *real-time* dos movimentos/gestos de mão do voluntário 4




Fonte: elaborado pelo autor (2021).

No ensaio do voluntário 4 é possível observarmos que o classificador confundiu em alguns intervalos os gestos 1 e 2 por apresentarem execuções parcialmente similares. Também é possível visualizar na figura que durante o intervalo de execução dos gestos 3, 6, 8, 9 e 10 os movimentos foram classificados como zero, o que sinaliza o cansaço do voluntário. Em termos de taxa de acerto de classificação, os voluntários 2, 3 e 4 obtiveram acurácias de 91,9%, 82,1% e 87,5% respectivamente. Embora tenhamos uma amostra muito pequena de voluntários, observamos que o sujeito 3 apresentou os menores resultados de acertos de classificação nos ensaios *offline* e *online*.

Contudo, a métrica da taxa de acerto de classificação não é comumente utilizada em situações de tempo real, pois ela não consegue avaliar o sistema completo (BI *et al.*, 2019). A fim de validar todo o sistema, uma prótese de código aberto com seis DoF foi incorporada aos ensaios *online*. Rotinas de comunicação entre as plataformas Raspberry Pi e Arduino, decodificação das instruções e acionamento elétrico foram implementadas. Desta forma, após a ocorrência de um gesto pelo voluntário, cada segmento de dados EMG é classificado e enviado a plataforma Arduino que executa o acionamento dos servomotores dando início a imitação do gesto pela prótese de mão. A figura 49 ilustra três exemplos de gestos realizados pela prótese: (a) pinça, (b) polegar e (c) pegada esférica.

Figura 49 - Exemplos de movimentos/gestos de mão realizados com a prótese



(a) movimento de pinça


(b) movimento de polegar

(c) movimento pegada cilíndrica

Fonte: elaborado pelo autor (2021).

Para a rotina de decodificação das instruções foi definido e implementado que a prótese mantivesse o gesto (sem reinicialização do movimento e acionamento dos motores de cada dedo) caso o movimento classificado fosse o mesmo do segmento anterior. Como experimento final, foram realizadas dez rodadas de preensão de três objetos pela prótese e a suas transferências entre dois pontos distantes 100 cm entre si. A figura 50 ilustra a sequência realizada neste ensaio, começando pela pega e transferência de um objeto retangular (objeto 1), na sequência uma garrafa plástica (objeto 2) e por último uma bola de tênis (objeto 3).

Figura 50 - Experimento de preensão e deslocamento de objetos



(a) objeto 1

(b) objeto 2

(c) objeto 3

Fonte: elaborado pelo autor (2021).

Para cada pega de objeto, um gesto diferente foi realizado pelo voluntário em concomitância com a tabela 11 (objeto 1 definido como mandril, objeto 2 como pegada cilíndrica e objeto 3 como pegada esférica).

Uma limitação neste ensaio foram os formatos de preensão executados pela prótese utilizada. No primeiro momento, foi considerado como objeto 1 uma garrafa plástica, onde a mão protética agarraria a tampa (gesto chamado de mandril) e deslocaria o objeto entre os pontos A e B. Devido à dificuldade de pega e foco na classificação correta do gesto, alteramos o objeto 1 para um elemento de formato retangular e ajustamos também as posições finais de cada dedo (servomotor) da prótese de mão e mantivemos a ação de realizar o gesto de mandril pelo voluntário. Outro desafio deste experimento foi estabelecer o movimento correto no momento que a prótese se aproximou do objeto a ser transferido do ponto A para o ponto B, pois como já apresentado nas análises anteriores, muitos erros de classificação ocorrem justamente nas transições dos gestos de mão e nenhuma rotina adicional foi testada e analisada nesta tese para atenuar este problema no sistema *real-time*



(no artigo do APÊNDICE H uma rotina foi desenvolvida e testada de forma *offline* no processamento dos bancos de dados KidoPro e NinaPro DB2, atenuando as mudanças de classe entre segmentos consecutivos). Desta forma estabelecemos que a contagem de conclusão de tarefas se iniciou a partir da primeira rodada realizada com sucesso. A tabela 14 apresenta o resultado obtido pelo voluntário 2 para as dez rodadas executadas.

Tabela 14 - Execuções do experimento de prensão e deslocamento de objetos

Tentativa	Tempo de execução (s)			Total
	Objeto retangular	Objeto cilíndrico	Objeto esférico	
1	12,5	23,8	17,4	53,7
2	14,7	15,9	8,6	39,2
3	16,8	24,7	11,4	52,9
4	15,2	46,9	19,1	81,2
5	14,1	30,4	13,2	57,7
6	X	-	-	-
7	X	-	-	-
8	22,3	16,8	20,7	59,8
9	13,3	X	-	-
10	15,8	18,5	22,3	56,6

Nota: X (falha de execução/trajetória), - (trajetória/gesto não executado)

Fonte: elaborado pelo autor (2021).

Os tempos médios para a transferência dos objetos foram de  $(15,6 \pm 3,0)$  s para o objeto retangular,  $(25,3 \pm 10,8)$  s para o objeto cilíndrico e  $(16,1 \pm 5,1)$  s para o objeto esférico (bola de tênis) e o tempo médio para a conclusão da tarefa foi de  $(57,3 \pm 12,5)$  s. Em termos de conclusão de tarefas, o voluntário atingiu 70% pois ocorreram falhas de execução nas rodadas 6, 7 e 9; nas duas primeiras execuções, a mão protética ao tocar no objeto retangular o deslocou e ele caiu da mesa. Na rodada 9 o objeto cilíndrico deslizou da prótese e também se deslocou para fora da mesa.

## 7 CONCLUSÕES E CONSIDERAÇÕES FINAIS

O objetivo deste trabalho foi de desenvolver contribuições quanto a aquisição, processamento e classificação de sinais eletromiográficos para utilização no acionamento de próteses elétricas via Aprendizado de Máquina. Ensaios preliminares de ajustes de hiperparâmetros e um conjunto de experimentos foram realizados para verificar alguns fatores que podem influenciar no desempenho dos classificadores, sendo os ensaios validados de forma *offline* através do processamento de duas bases de dados públicas NinaPro. O experimento usando sinais EMG e acelerômetros simultaneamente mostrou um aumento significativo no desempenho de classificação de indivíduos amputados e intactos. No experimento com técnicas de redução de dimensionalidade, os resultados provaram que a acurácia da classificação pode ser melhorada combinando a projeção LDA com os classificadores testados. No entanto, não produziu melhor taxa de acerto de classificação combinando PCA com os classificadores. A seção 6.1.1 mostrou que os modelos implementados de Rede Neural Multilayer Perceptron e Floresta Aleatória apresentaram acurácias médias de classificação muito próximas, enquanto os modelos implementados de Redes Neurais Convolucionais e Redes Neurais Recorrentes apresentaram taxas de acerto médias inferiores às taxas dos outros classificadores. Estes dois melhores modelos apresentaram métricas (de classificação) equivalentes a literatura existente e desta forma uma etapa *online* foi proposta e conduzida, primeiramente com o desenvolvimento de um banco de dados de sinais EMG de voluntários locais e em seguida com os testes de classificação. As acurácias médias obtidas utilizando os dados/sinais dos voluntários locais, considerando 11 classes, foram de 96,3% para o sistema *offline* e de 87,2% para o sistema *online*. O tempo de processamento médio das etapas de pré-processamento, cálculo de *features* e classificação foi menor que 11 ms e desta forma consideramos a implementação capaz de responder em tempo real. O sistema de reconhecimento de gestos ainda foi integrado a uma *interface* de acionamento elétrico e a uma prótese *open source* e um ensaio de prensão de objetos e transferência entre dois pontos foi realizado com um voluntário local. Ele foi capaz de executar de forma *real-time* as ações solicitadas sendo o resultado do experimento considerado satisfatório do ponto de vista funcional.

Além das contribuições resumidas anteriormente, o desenvolvimento deste estudo pode colaborar na submissão de artigos e na orientação de trabalhos de conclusão de curso pelo autor da tese. Estas contribuições estão descritas na seção 7.1 deste trabalho. Também apresentamos na seção 7.2 possíveis oportunidades de continuidade a partir da finalização desta etapa da tese.

## 7.1 CONTRIBUIÇÕES ACADÊMICAS


Até o momento dois artigos foram submetidos e aceitos em periódico e/ou congresso: o primeiro artigo foi publicado e disponibilizado no livro eletrônico da Springer Nature com o título *Real-time hand prosthesis biomimetic movement based on electromyography sensory signals treatment and sensors fusion* (SOUZA, 2018). Ele descreve uma proposta de *hardware* e *software* para o controle de uma prótese de mão *open source* (maiores informações estão disponíveis no APÊNDICE G). O segundo artigo, aceito no periódico IEEE Sensors com o título *Investigation of Different Approaches to Real-Time Control of Prosthetic Hands with Electromyography Signals* (APÊNDICE H), apresenta uma investigação dos recursos (classificadores, número de canais EMG, outros sensores e redução da dimensionalidade) para o controle *real-time* de uma prótese de mão utilizando sensores mioelétricos e aprendizado de máquina. Também foi criado um banco de dados contendo sinais EMG de onze gestos de mão de cinco voluntários locais para experimentos no reconhecimento destes movimentos (SOUZA, 2021).

Além dos artigos, nos últimos dois anos o autor da tese orientou oito alunos dos cursos de Engenharia da Computação, Engenharia de Controle e Automação, Engenharia Elétrica e Engenharia Eletrônica desta Universidade nos seus respectivos Trabalhos de Conclusão de Curso (TCC) em assuntos pertinentes à área da tese. Um resumo destes trabalhos é apresentado a seguir dividindo em três áreas: próteses e robôs, instrumentação e aquisição de biosinais e processamento/classificação de sinais EMG.

Em termos de próteses e sistemas robóticos, o trabalho desenvolvido por RIBEIRO (2019) apresentou o protótipo de um acionamento elétrico para prótese de mão por meio de comando de voz de forma a realizar movimentos pré-definidos na tradução de letras para a língua brasileira de sinais (LIBRAS). A aplicação foi desenvolvida na plataforma Raspberry Pi, onde o dispositivo foi responsável pela

aquisição do áudio, conversão para textos e acionamento dos motores da prótese. A figura 51 ilustra um exemplo da execução do sistema após a aquisição e processamento de um comando de voz (palavra bola).


Figura 51 - Execução de gestos através do reconhecimento de voz



Fonte: adaptado de Ribeiro (2019).

Na área de instrumentação e aquisição de sinais, o trabalho de conclusão desenvolvido por SANTOS (2021) apresentou o protótipo de um bracelete de baixo custo capaz de adquirir simultaneamente até quatro canais de sinais EMG sendo expansível para até três dispositivos, chegando a 12 canais EMG. O sistema (figura 52) foi composto pelas etapas de condicionamento de sinais, aquisição de biosinais através de eletrodos de superfície e comunicação via Bluetooth com a interface gráfica instalada no computador.


Figura 52 - Dispositivo para aquisição de sinais EMG: (a) bracelete com eletrodos, condicionador de sinais, sistema embarcado e bateria; (b) posicionamento do bracelete para experimentos; (c) interface gráfica com os sinais EMG adquiridos



Fonte: adaptado de Silva (2021).

Outro trabalho que envolveu a aquisição de biosinais foi o TCC apresentado por Pinto (2021). Ele desenvolveu o protótipo de um sistema embarcado para aquisição de sinais eletroencefalográficos (EEG) em tempo real (figura 53). O sistema possui os seguintes blocos: oito eletrodos (canais) EEG, condicionadores de sinais (um para cada canal), conversores analógico-digitais, processamento digital de sinais através da plataforma Raspberry Pi e comunicação via TCP (*Transmission Control Protocol*) com software supervisor instalado no computador.

Figura 53 - Dispositivo para aquisição de sinais EEG: (a) placa de circuito impresso do condicionador de sinais; (b) posicionamento dos eletrodos EEG



Fonte: adaptado de Pinto (2021).

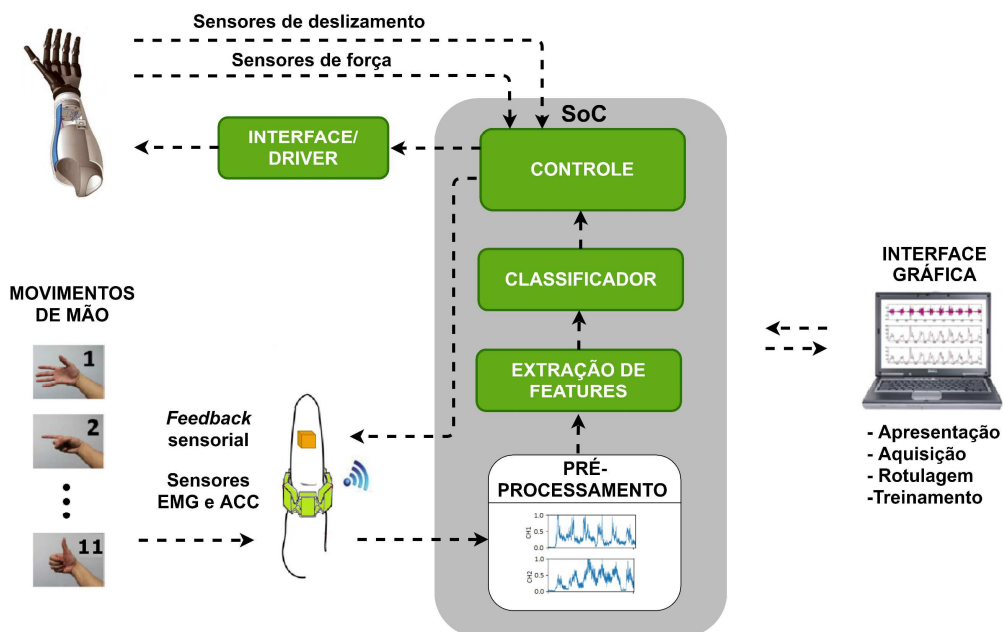
Em termos de classificadores, BOELTER (2021) utilizou uma base de dados de sinais mioelétricos (NinaPro) para a classificação de gestos e movimentos de mão para o controle de uma prótese. Três diferentes estruturas de classificadores foram implementadas em um computador *desktop* e comparadas: Rede Neural Artificial (arquitetura MLP), Análise Discriminante Linear e Floresta Aleatória. Ele observou em seus experimentos, que a Floresta Aleatória foi a mais promissora das três técnicas e com acurácia que variou de 92% para 5 movimentos de mão a 84% para 53 classes. Ainda em relação a sistemas de classificação, RUBO (2020) apresentou um emulador de sinais EMG juntamente com as etapas de pré-processamento, extração de *features* e classificação dos movimentos/gestos de mão. Na etapa de cálculo de *features* foram consideradas 15 características no domínio do tempo e 10 características no domínio da frequência. O sistema apresentou para o ciclo de processamento dos sinais EMG um tempo de aproximadamente 30 ms para um classificador MLP.

Até o momento, dois trabalhos de conclusão de curso estão em andamento. O primeiro TCC é o projeto de um protótipo de acionamento elétrico de uma prótese de mão *open source* com seis graus de liberdade, contemplando as etapas de impressão da prótese, montagem, testes elétricos e decodificação de instruções provenientes de uma plataforma de prototipação rápida que realiza a aquisição, pré-processamento e classificação de sinais EMG. O segundo trabalho de conclusão contemplará a construção de uma interface gráfica para apresentação de movimentos/gestos de mão através de vídeo e a aquisição e rotulagem de sinais EMG de voluntários locais. Estes trabalhos estão com previsão de entrega e defesa para maio de 2022.

## 7.2 CONTINUIDADE E SUGESTÕES DE TRABALHOS FUTUROS

Com a finalização deste trabalho, algumas oportunidades de melhorias e novos estudos/experimentos ligados a tese são ilustrados no diagrama de blocos da figura 54.

Figura 54 - Diagrama de blocos apresentando as oportunidades de trabalhos futuros a partir desta tese



Fonte: Elaborado pelo autor (2021).

Para explicar o diagrama de blocos anterior com as oportunidades, dividimos a seção em quatro tópicos: instrumentação eletroeletrônica, banco de dados, processamento e classificação de sinais e sistema mecânico (prótese).

### 7.2.1 Instrumentação eletroeletrônica

A primeira oportunidade de continuidade é com relação à área de instrumentação eletroeletrônica destacando o estudo de quatro pontos:

- a) inclusão de sinais de *feedback* à prótese: sensores de força e deslizamento com o objeto de monitorar a pressão dos cinco dedos da mão protética quando ela segura um objeto e detectar eventos de escorregamento do elemento. Com o deslizamento detectado, o sistema incrementará o valor da força na saída até um valor limite. Esta inclusão também permitirá a redefinição das posições finais de cada motor (servomotor) da prótese para objetos de mesmo formato (de acordo com o gesto classificado), mas com dimensões/volumes diferentes;
- b) realimentação sensorial não invasiva: para os voluntários/usuários de próteses a utilização de sistemas vibrotáteis (por exemplo, pequenos motores, solenóides ou atuadores ressonantes) que informem/traduzem o quanto de força de preensão está sendo aplicada pela prótese ao elemento/objeto;
- c) aquisição de outros sinais: por exemplo de acelerometria para geração de um novo banco de dados para classificadores multimodais realizando a fusão das informações de sinais EMG e ACC com o intuito de incrementar o desempenho de classificação dos sistemas de reconhecimento de gestos/movimentos de mão;
- d) desenvolvimento de um bracelete com eletrodos de superfície ativos (possui um pré-amplificador em cada eletrodo onde o sinal EMG é amplificado e as interferências do ambiente são atenuadas) de aço inoxidável ou de outro metal disponível com o objetivo de tornar o dispositivo vestível para o usuário da prótese.

### 7.2.2 Expansão do banco de dados de voluntários locais

Através deste trabalho, desenvolvemos e apresentamos a primeira versão de nosso banco de dados EMG e algoritmos/rotinas de pré-processamento, cálculo de *features* e classificação para auxiliar diferentes grupos de estudo em suas pesquisas e experimentos de reconhecimento de gestos/movimentos de mão, a fim de melhorar o desempenho dos classificadores e desenvolver sistemas de controle de próteses mioelétricas. Novos dados de sensores EMG (e de outros sinais como

ACC) de indivíduos intactos e voluntários amputados serão adicionados ao *dataset*. Além da inclusão de mais voluntários e biosinais, outro ponto em questão é o aumento do número de movimentos a serem classificados. Como ponto de partida, podem ser considerados os exercícios B (movimentos básicos dos dedos e pulso) e C (movimentos de preensão de objetos e funcionais) dos bancos de dados NinaPro DB2 e DB3 (ATZORI *et al.*, 2014a).

Uma segunda oportunidade em relação ao banco de dados de voluntários locais é a melhoria da *interface* para geração do *dataset* e treinamento dos classificadores. Atualmente, a versão desenvolvida é limitada, sendo todos os blocos (aquisição, rotulagem e classificação) integrados de forma manual. Nesta nova versão, uma aplicação única deverá executar em computador *desktop* a apresentação dos vídeos de gestos/movimentos mão (básicos, funcionais e/ou de preensão de objetos), realizar a comunicação com o(s) dispositivo(s) de aquisição de sinais, gravar e rotular os dados e ter a opção de efetuar o processamento deste banco de dados para diferentes classificadores. As configurações e parâmetros dos classificadores deverão ser salvos e carregados de forma simples no sistema embarcado da prótese que possui um menor poder computacional.

Outro tópico importante é a integração deste trabalho com a área da saúde (fisioterapia, psicologia, nutrição e educação física) que diretamente impacta no desempenho de usuários de próteses, visto que o condicionamento físico e mental dos amputados é essencial para a utilização de próteses. Isto pôde ser evidenciado nos experimentos com os bancos de dados NinaPro, onde os voluntários amputados que utilizavam próteses mioelétricas atingiram as maiores taxas de acerto, sendo nestes casos valores de acurácia próximos aos resultados apresentados pelos voluntários não amputados.

### **7.2.3 Pré-processamento e classificação de sinais EMG**

Como proposta de continuidade ainda podemos citar possibilidades de novas contribuições em relação ao pré-processamento, classificação e pós-processamento dos sinais EMG e de outros sinais que compõem o sistema de reconhecimento de gestos de mão, considerando todas estas etapas blocos que podem ser incluídos ou substituídos a partir do sistema desenvolvido nesta tese. Em relação a etapa de pré-processamento citamos a implementação e análise de técnicas de filtragem como filtro de Kalman (DUTRA *et al.*, 2018) e a Transformada



de Antonyan Vardan (AVT - *Antonyan Vardan Transform*) (CENE *et al.*, 2018) com o objetivo de atenuar os ruídos dos artefatos de movimentos e da rede elétrica e proporcionar a menor alteração nas características (*features*) dos sinais adquiridos. Em termos de classificadores, consideramos também a possibilidade da implementação e análise comparativa de modelos de classificadores mais tradicionais como SVM e k-NN (ABBASPOUR *et al.*, 2020 e ROBINSON *et al.*, 2017) e algoritmos promissores como ELM (CENE *et al.*, 2018) juntamente com métodos de pós-processamento como *Major-Voting* (BENATTI *et al.*, 2017).


#### 7.2.4 Prótese de mão

Embora os resultados dos testes de preensão de objetos tenham obtidos bons resultados, uma limitação de hardware foi observada na prótese utilizada. Estas limitações são descritas por Tian e colaboradores (2017) que utilizaram o mesmo projeto de prótese de código aberto em seus experimentos. As principais limitações descritas por eles e que também impactaram nossos experimentos foram: (a) a força que os cinco motores podem produzir é menor que a força de preensão da mão humana (limitação de agarrar objetos pesados); (b) o tipo de material da prótese (PLA) é incapaz de suportar tamanha força e limita também a preensão de objetos pesados; (c) a superfície da mão robótica impressa em 3D é sólida e lisa dificultando a criação de atrito suficiente ao segurar um objeto pesado. Este último item foi um dos pontos responsáveis pelas falhas ocorridas em nossos ensaios. Com isso, consideramos o desenvolvimento de um novo projeto mecânico e elétrico da prótese de mão. A seguir, são descritas as informações técnicas dos sistemas mecânicos e elétricos que compõem este novo protótipo.

##### 7.2.4.1 Sistema mecânico

Uma nova prótese de mão de baixo custo está em desenvolvimento pelas empresas Petron Sistemas Eletrônicos (João Olegario de Oliveira de Souza EPP) e TEKMES (Tonhelski & Souza Ltda). A prótese possui cinco dedos acionados individualmente e ainda o deslocamento lateral do dedo polegar, totalizando seis DoF. Cada dedo é acionado por um motor de corrente contínua, permitindo alterar a força de preensão dedo por dedo. A figura 55 mostra duas imagens do protótipo.

Figura 55 - Sistema mecânico da prótese de mão



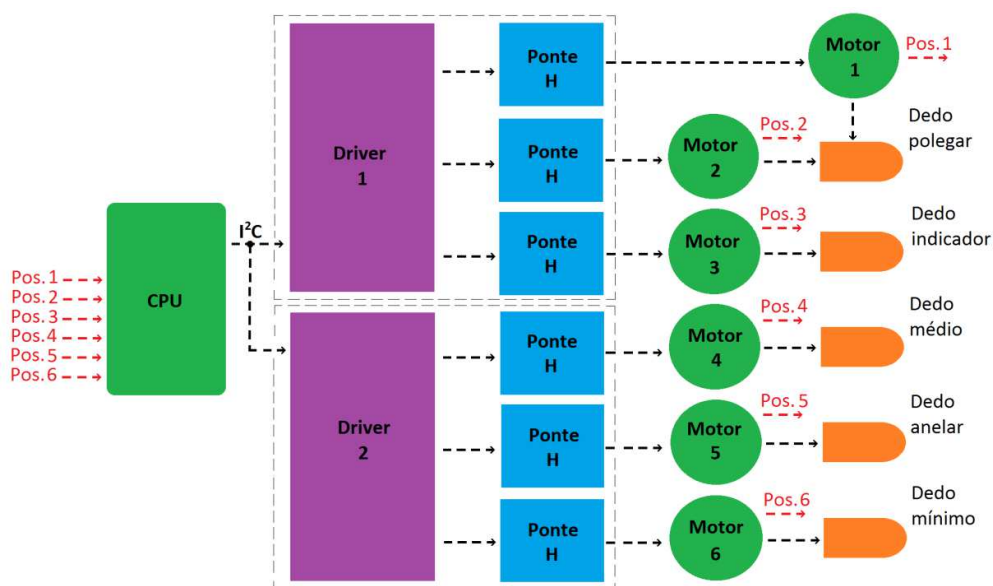
Fonte: Elaborado pelo autor (2021).

Como outras características do projeto, podemos citar o peso de 550 gramas, utilização de PLA (Ácido polilático) na impressão da maioria das peças e alojamento na palma da mão de todos os motores e engrenagens que compõem o sistema.

#### 7.2.4.2 Motores elétricos, *encoders* e *drivers*

A figura 56 apresenta o diagrama de blocos do acionamento elétrico dos dedos da prótese de mão. Um motor de corrente contínua com caixa de redução é acoplado em cada dedo e mais um motor é inserido para o movimento lateral do polegar, totalizando seis elementos.

Figura 56 - Diagrama de blocos do acionamento elétrico



Fonte: Elaborado pelo autor (2021).

As especificações técnicas deste modelo de motor podem ser conferidas no quadro 9. Estes motores possuem baixa velocidade de rotação aliados a um bom torque (POLOLU, 2021).

Quadro 9 - Especificações dos motores de corrente contínua




Descrição	Especificação
Alimentação	6 V/70 mA (sem carga)
Torque	11 kg.cm/1,5 A (máximo)
Velocidade	33 RPM
Redução	1000:1
Dimensões	44 mm x 12 mm x 10 mm

Fonte: Adaptado de Pololu (2021).

Além disso, um *encoder* magnético é encaixado no eixo traseiro de cada motor para medição da velocidade do motor ou *feedback* de posição. O módulo possui duas saídas digitais (A e B) em quadratura. A leitura de apenas um canal fornece apenas a velocidade, enquanto a leitura dos dois canais (figura 57 fornece além da velocidade, o sentido de rotação (POLOLU, 2021). No diagrama de blocos da figura 56, cada par de informações é representado pela nomenclatura Pos. x, onde x é o motor correspondente.

Figura 57 - Leitura de velocidade e sentido de rotação de motor




Fonte: Adaptado de Pololu (2021).

Para o acionamento dos seis motores serão utilizados dois módulos modelo Zero Borg (figura 58.a) da empresa Pi Borg (nome registrado da Freeburn Robotics Ltd). Cada módulo consegue controlar até quatro motores de forma independente

através de ponte completa (*full H-bridge*) com corrente de 1,5 A RMS (por ponte). O sistema é compatível com a plataforma Raspberry Pi Zero (figura 58.b) podendo empilhar até três módulos via comunicação I<sup>2</sup>C.

Figura 58 - *Driver* para acionamento dos motores de corrente contínua



(a) Placa Zero Borg

(b) Conexão com Raspberry Pi Zero

Fonte: Adaptado de PiBorg (2021).

Com a utilização dos *encoders* magnéticos na medição de posição, será possível o desenvolvimento das rotinas de controle de cada dedo de acordo com o movimento a ser executado pela prótese.

#### 7.2.4.3 Outros recursos e experimentos

Nesta nova versão de prótese de mão, para melhorar a aderência entre a prótese e os objetos, também serão realizados dois experimentos de preensão: (a) cobrindo os dedos e palma da mão protética com material de silicone conforme mostrado em Liow *et al.* (2020) e Cordella e colaboradores (2016); (b) inserindo uma luva de silicone na prótese conforme apresentado em Weiner e colaboradores (2020) e Tian *et al.* (2017). Trabalhos futuros também serão propostos com outros objetos e outras configurações de pega.

## REFERÊNCIAS

ABBASPOUR, S.; LINDÉN, M.; GHOLAMHOSSEINI, H.; NABER, A.; ORTIZ-CATALAN M. **Evaluation of surface EMG-based recognition algorithms for decoding hand movements**. Medical & Biological Engineering & Computing, vol. 53, p.33-100, 2020.

ALPAYDIN, E. **Introduction to Machine Learning**. 2. ed. MIT Press, 2010.

AL-TIMEMY, A. H.; BUGMAN, G.; ESCUDERO, J. **Classification of Finger Movements for the Dexterous Hand Prosthesis Control with Surface Electromyography**. IEEE Journal of Biomedical and Health Informatics, vol. 17(3), p. 608 - 618, 2013.

ALTAMIRANO, A. A. **EMG Pattern Prediction for Upper Limb Movements Based on Wavelet and Hilbert-Huang Transform**. Doutorado. Université de Lorraine; Instituto Politécnico Nacional (México), 2017.

AMERI, A.; AKHAEI, M. A.; SCHEME, E.; ENGLEHART, K. **Real-Time, Simultaneous Myoelectric Control using a Convolutional Neural Network**. PLoS ONE, 2018.

ANACONDA, 2019. **Anaconda Individual Edition**. Disponível em <https://www.anaconda.com/products/individual>. Acesso em: 20/02/2019.

ARDUINO. **Getting Started with Arduino and Genuino UNO**. Disponível em: <https://www.arduino.cc/en/Guide/ArduinoUno/> Acesso em: 25/11/2018.

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

ATZORI, M.; GIJSBERTS, A.; CASTELLINI, C.; CAPUTO, B.; HAGER, A.G.M.; ELSIG, S.; GIATSIDIS, G.; BASSETTO, F.; HEYNEN.; MÜLLER, H.

**Electromyography data for non-invasive naturally-controlled robotic hand prostheses.** Scientific data, 2014a.

ATZORI, M.; GIJSBERTS, A.; CASTELLINI, C.; MÜLLER, H.; CAPUTO, B.; **Classification of hand movements in amputated subjects by sEMG and accelerometers.** International Conference IEEE Engineering in Medicine and Biology Society, 2014b

ATZORI, M.; GIJSBERTS, A.; HEYNEN, S.; HAGER, A.G.M.; DERIAZ, O.; VAN DER SMAGT, P.; CASTELLINI, C.; CAPUTO, B.; MÜLLER, H. **Building the Ninapro database: A resource for the biorobotics community.** In: Biomedical Robotics and Biomechatronics (BioRob), 2012 4th IEEE RAS & EMBS International Conference, p. 1258-1265, 2012.

ATZORI, M.; GIJSBERTS, A.; KUSBORSKIJ, I.; ELSIG, S.; HAGER, A.G.M.; DERIAZ, O.; CASTELLINI, C.; MÜLLER, H.; CAPUTO, B. **Characterization of a benchmark database for myoelectric movement classification.** IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol. 23, no. 1, p. 73-83, 2015.

ATZORI, M.; MÜLLER, H. **Control Capabilities of Myoelectric Robotic Prostheses by Hand Amputees: A Scientific Research and Market Overview.** Frontiers in Systems Neuroscience, 2015.

ATZORI, M.; MÜLLER, H. **PaWFE: Fast Signal Feature Extraction Using Parallel Time Windows.** Frontiers in Systems Neuroscience, 2019.

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

BEAGLE. **Beaglepocket board.** Disponível em <https://beagleboard.org/pocket/>. Acesso em: 25/11/2018.

BEBIONIC. **Bebionic3 Technical Information.** Disponível em: <http://bebionic.com/>. Acesso em: 25/11/2018.

BENATTI, S.; MILOSEVIC, B.; FARELLA, E.; GRUPPIONI, E.; BENINI, L. **A Prosthetic Hand Body Area Controller Based on Efficient Pattern Recognition Control Strategies**. *Sensors*, vol. 17, 2017.

BI, L.; FELEKE, A. G.; GUAN, C. **A review on EMG-based motor intention prediction of continuous human upper limb motion for human-robot collaboration**. *Biomedical Signal Processing and Control*, vol. 51, p. 113-127, 2019.

BIONICENTER. **O que é amputação de braço? Principais causas e Tipos de Próteses**. Disponível em: <https://bionicenter.com.br/o-que-e-amputacao-de-braco-principais-causas-e-tipos-de-protese/> Acesso em: 12/08/2021.

BISHOP, C. M. **Pattern Recognition and Machine Learning**. Information Science and Statistics, Springer, 2006.

BITALINO. **Plataforma MuscleBIT BT**. Disponível em: <https://bitalino.com/products/musclebit-bt>. Acesso em: 02/09/2020.

BOELTER, J. S. **Classificação de Sinais Eletromiográficos utilizando Redes Neurais Artificiais, Análise Discriminante Linear e Floresta Aleatória**. Trabalho de Conclusão de Curso. Engenharia Eletrônica. Universidade do Vale do Rio dos Sinos (UNISINOS), 2021.

BREIMAN, L.; FRIEDMAN J.; STONE, C. J.; OLSHEN, R.A. **Classification and regression trees**. Chapman and Hall, 1984.

BREIMAN, L. **Bagging predictors Machine Learning**. Kluwer Academic Publishers, vol. 24, p.123-140, 1996.

BREIMAN, L. **Random Forests in Machine Learning**. Statistics Department, University of California, Berkeley. Kluwer Academic Publishers, 2001.

CENE, V. H.; BALBINOT, A. **Using the sEMG signal representativity improvement towards upper-limb movement classification reliability**. *Biomed. Signal Process. Control*, vol. 46, p. 182-191, 2018.

CENE, V. H.; TOSIN, M.; MACHADO, M.; BALBINOT, A. **Open Database for Accurate Upper-Limb Intent Detection Using Electromyography and Reliable Extreme Learning Machines**. *Sensors*, vol. 19, 1864, 2019.

CENE, V. H.; SANTOS, R. R. DOS; BALBINOT, A. **Using antonyan vardan transform and extreme learning machines for accurate sEMG signal classification**. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, vol. 40, 2018.

CHOLLET, F. **Deep Learning with Python**. Manning Publications, 2018.

CINELLI, M. J.; DOMENECH, S. C.; FERREIRA, M. G. G.; RODRIGUES, R. S. **O Design de próteses open source para membros superiores por meio da análise documental de projetos**. *e-Revista LOGO*, vol. 5, n.2, 2016.

COOKING-HACKS. **E-health sensor platform**. Disponível em: <http://www.cooking-hacks.com/documentation/tutorials/ehealth-biometric-sensor-platform-arduino-raspberry-pi-medical/>. Acesso em: 25/11/2018.

CORDELLA, F.; DAVALLI, A.; CUTTI, A.G.; ZOLLO, L. **Literature Review on Needs of Upper Limb Prosthesis Users**. *Frontiers in Neuroscience*, 2016.

CÔTÉ-ALLARD, U.; FALL, C.L.; CAMPEAU-LECOURSs, A.; GOSSELIN, C.; LAVIOLETTE, F.; GOSSELIN, B. **Transfer Learning for sEMG Hand Gestures Recognition Using Convolutional Neural Networks**. *IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, Canada, p. 1663 - 1668, 2017.

DE LUCA, C. J. **The use of surface electromyography in biomechanics**. *Journal of Applied Biomechanics*, vol. 13, 1997.

DE LUCA, C. J. **Electromyography**. *Encyclopedia of Medical Devices and Instrumentation*, (John G. Webster, Ed.) John Wiley Publisher, p. 98-109, 2006.

DE LUCA, C. J. **Surface Electromyography: detection and recording**. Delsys Incorporated, 2002.



DIGIKEY. **Distribuidor autorizado de componentes eletrônicos**. Disponível em: <http://www.digikey.com/>. Acesso em: 07/01/2019.

DING, Z.; YANG, C.; TIAN, Z.; YI, C.; FU, Y.; JIANG, F. **sEMG-Based Gesture Recognition with Convolution Neural Networks**. Sustainability, vol 10(6):1865, 2018.

DUTRA, B. G.; CASTRO, L. A. M.; AMORIM, G.; SILVEIRA, A. S. **Estimação de movimentos de punho em tempo real com filtro de Kalman para controle de próteses ativas funcionais**. Congresso Brasileiro de Automática, v. XXII, p. 1, 2018.

ENGELBERG, A. M. A. **Guides to the evaluation of permanent impairment**. American Medical Association Press, 1990.

ENGLEHART, K; HUDGINS, B. **A Robust, Real-Time Control Scheme for Multifunction Myoelectric Control**. IEEE Transactions on Biomedical Engineering, vol. 50(7), p. 848-854, 2003.

EXIII. **HACKberry Open source community**. Disponível em: <http://exiii-hackberry.com/>. Acesso em: 27/12/2018.

FARREL, T. R. **Determining delay created by multifunctional prosthesis controllers**. Journal of Rehabilitation Research & Development (JRRD), vol. 48(6), 2011.

FARREL, T. R.; WEIR, R. F. **A comparison of the effects of electrode implantation and targeting on pattern classification accuracy for prosthesis control**. IEEE Transactions on Biomedical Engineering, vol. 55 (9), p. 2198-2211, 2008.

FAWCETT, T. **An introduction to ROC analysis**. Pattern Recognition Letters, vol. 27(8), p. 861-874, 2006.

FOUGNER, A.; SCHEME, E.; CHAN, A. D. C., ENGLEHART, K.; STAVDAHL, Ø. **A multi-modal approach for hand motion classification using surface emg and**

**accelerometers.** Annual International Conference of the IEEE Engineering in Medicine and Biology Society, p. 4247-4250, 2011.

FRIDLUND, A. J.; CACIOPPO, J. T. **Guidelines for Human Electromyographic Research.** Psychophysiology, v. 23, n. 5, p. 567-589, 1986.

GAZZONI, M.; CELADON, N.; MASTRAPASQUA, D.; PALEARI, M.; MARGARIA, V.; ARIANO, P. **Quantifying forearm muscle activity during wrist and finger movements by means of multi-channel electromyography.** PLoS ONE, 2014.

GEETHANJALI, P. **Myoelectric control of prosthetic hands: state-of-the-art review.** Medical Devices: Evidence and Research, vol. 9, p. 247-255, 2016.

GEETHANJALI, P.; RAY, K.K. **A Low-Cost Real-Time Research Platform for EMG Pattern Recognition-Based Prosthetic Hand.** IEEE/ASME Transactions on Mechatronics, 2014.

GENG, W.; DU, Y.; JIN, W.; WEI, W.; HU, Y.; LI, J. **Gesture recognition by instantaneous surface EMG images.** Scientific Reports, vol. 6(1):36571, 2016.

GERHARDT, T. E.; SILVEIRA, D.T. **Métodos de Pesquisa.** 1. ed. Editora UFRGS, 2009.

GIJSBERTS, A.; ATZORI, M.; CASTELLINI, C.; MÜLLER, H.; CAPUTO, B. **Movement Error Rate for Evaluation of Machine Learning Methods for sEMG-Based Hand Movement Classification.** IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol. 22(4), p. 735-744, 2014.

GILROY, Anne M. MACPHERSON, B. **Atlas de Anatomia.** 3 ed. Rio de Janeiro: Guanabara Koogan, 2017.

GINI, G.; ARVETTI, M.; SOMLAI, I.; FOLGHERAITER, M. **Acquisition and analysis of EMG signals to recognize multiple hand movements for prosthetic applications.** Applied Bionics and Biomechanics, vol. 9, p. 145-155, 2012.

GODOI, T. S. M.; DUQUE, L. H.; DÍAZ, F. J. O. **Prótese mioelétrica controlada por Redes Neurais.** Revista Universitas Gestão e TI, vol. 3(2), 2013.

GONZALEZ, R. C.; WOODS, R. E. **Processamento Digital de Imagens**. 3. ed. Pearson, 2010.

GOODFELLOW, I., BENGIO, Y., COURVILLE, A. **Deep Learning**. MIT Press, 2016. Disponível em: <http://www.deeplearningbook.org/>. Acesso em: 07/12/2018.

GREFF, K.; SRIVASTAVA, R. K.; KOUTNÍK, J.; STEUNEBRINK, B. R.; SCHMIDHUBER, J. **LSTM: A Search Space Odyssey**. IEEE Transactions on Neural Networks and Learning Systems, vol. 28(10), p. 2222 - 2232, 2017.

GRUBER, L.; LAU, T. M. **Upper Limb Prosthetics**. Medical Rehabilitation. American Academy of Physical Medicine and Rehabilitation, 2014. Disponível em: <https://now.aapmr.org/upper-limb-prosthetics/>. Acesso em: 07/03/2021.

GUNJI, D.; MIZOGUCHI, Y.; TESHIGAWARA, S.; AIGUO MING; NAMIKI, A.; ISHIKAWAAND, M.; SHIMOJO, M. **Grasping force control of multi-fingered robot hand based on slip detection using tactile sensor**. IEEE International Conference on Robotics and Automation, p. 2605-2615, 2008.

GUYTON, A. C.; HALL, J. E. **Tratado de Fisiologia Médica**. 13. ed. Rio de Janeiro, RJ: Elsevier, 2017.

HAFF, G. G.; TRIPLETT, N. T. **Essentials of Strength Training and Conditioning**. 4. ed. National Strength & Conditioning Association, 2016.

HALL, S.J. **Biomecânica Básica**. 7. ed. Rio de Janeiro: Guanabara Koogan, 2016.

HANLEY, J. A.; McNEIL, B. J. **The meaning and use of the area under a receiver operating characteristic (ROC) curve**. Radiology, vol. 143(1), p. 29-36, 1982

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2011.

HERMENS, J.H.; FRERIKS, B. KLUG, C.D.; RAU, G. **Development of recommendations for SEMG sensors and sensor placement procedures**. Journal of Electromyography and Kinesiology., vol.14, p. 361-74, 2000.

HOCHREITER, SEPP; SCHMIDHUBER, JÜRGEN. **Long short-term memory**. Neural computation, vol. 9, n. 8, p. 1735 -1780, 1997.

HOPFIELD, J. J. **Neural Networks and Physical Systems with Emergent Collective Computational Abilities**. Proceedings of National Academy of Sciences, Vol. 79, p. 2554-2558, 1982.

HUMAN TECHNOLOG. **Prosthetics and Orthotics**. Disponível em [https://humantechpando.com./](https://humantechpando.com/). Acesso em: 21/07/2021.

HUNTER, J.D. **Matplotlib: A 2D Graphics Environment**. Computing in Science & Engineering, vol. 9(3), p. 90-95, 2007.

IBRAHIMY, M.I.; AHSAN, M.R.; KHALIFA, O.O. **Design and Performance Analysis of Artificial Neural Network for Hand Motion Detection from EMG Signals**. World Applied Sciences Journal, vol. 23 (6), p. 751-758, 2013.

INTEL. **Introdução às Placas Intel Galileo**. Disponível em <https://www.intel.com.br/content/www/br/pt/support/articles/000005912/boards-and-kits/intel-galileo-boards.html/>. Acesso em: 26/12/2018.

JARQUE-BOU, N. J.; ATZORI, M.; MÜLLER, H. **A large calibrated database of hand movements and grasps kinematics**. Scientific Data, vol. 7(12), 2020.

JONES, E.; OLIPHANT, T.; PETERSON, P. **SciPy: Open source scientific tools for Python**, 2001. Disponível em: <http://www.scipy.org>. Acesso em: 20/12/2019.

KAMEN, G.; CALDWELL, G. E. **Physiology and Interpretation of the Electromyogram**. Journal of Clinical Neurophysiology, vol. 13, n. 5, p. 366-384, 1996.

KAPANDJI, I. A. **Fisiologia Articular: esquemas comentados de mecânica humana**.v.1, 5 ed. São Paulo: Panamericana, 2000.

KARPATHY, A. **A Convolutional Neural Networks for Visual Recognition**. Disponível em <http://cs231n.github.io/convolutional-networks/>. Acesso em: 26/12/2018.

KHEZRI, M.; JAHED, M. **A Neuro–Fuzzy Inference System for sEMG-Based Identification of Hand Motion Commands.** IEEE Transactions on Industrial Electronics, vol. 58, n. 5, p. 1952-1960, 2011.

KHUSHABA, R.; AL-TIMEMY, A.; KODAGODA, S.; NAZARPOUR, K. **Combined influence of forearm orientation and muscular contraction on EMG pattern recognition.** Expert Systems with Applications, vol. 61, p.154-161, 2016.

KIM, K.; GUAN, C.; LEE, S. **A Subject-Transfer Framework based on Single-Trial EMG Analysis using Convolutional Neural Networks.** IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol. 28, p. 94-103, 2019.

KONRAD, Peter. **The ABC of EMG: A Practical Introduction to Kinesiological Electromyography.** Estados Unidos: Noraxon, 2005.

KRASOULIS, A.; KYRANOU, I.; ERDEN, M. S.; NAZARPOUR, K.; VIJAYAKUMAR, S. **Improved prosthetic hand control with concurrent use of myoelectric and inertial measurements.** Journal of Neuroengineering and Rehabilitation, vol. 14 (71), 2017.

KYRANOU, I.; KRASOULIS, A.; ERDEN, M. S.; NAZARPOUR, K.; VIJAYAKUMAR, S. **Real-Time Classification of Multi-Modal Sensory Data for Prosthetic Hand Control.** IEEE International Conference on Biomedical Robotics and Biomechatronics (*BioRob*), p. 536-541, 12016.

LAEZZA, R. **Deep Neural Networks for Myoelectric Pattern Recognition: An Implementation for Multifunctional Control.** Mestrado em Engenharia Elétrica. Chalmers University of Technology (Suécia), 2018.

LANGEVIN, G. **InMoov - Open Source 3D Printed Life Size Robot.** Disponível em: <http://inmoov.fr/>. Acesso em: 26/12/2018.

LEHMAN, G.J.; MCGILL, S.M. **The importance of normalization in the interpretation of surface electromyography: a proof of principle.** Journal of Manipulative and Physiological Therapeutics, vol. 22, 1999.

LI, X.; ZHOU P.; ARUIN, A.S. **Teager-Kaiser energy operation of surface EMG improves muscle activity onset detection**. *Annals of Biomedical Engineering*, vol. 35, p. 1532-1538, 2007.

LIOW, L.; CLARK, A. B.; ROJAS, N. **OLYMPIC: A Modular, Tendon-Driven Prosthetic Hand With Novel Finger and Wrist Coupling Mechanisms**. *IEEE Robotics and Automation Letters*, vol. 5, n. 2, 2020.

LUCHETTI, M.; MONTEBAROCCI, O.; ROSSI, N.; CUTTI, A. G.; SUTIN, A. R. **Autobiographical Memory and Psychological Distress in a Sample of Upper-Limb Amputees**. *PloS one*, vol. 9 (6), 2014.

LV, B.; SHENG, X.; GUO, W.; ZHU, X.; DING, H. **Towards Finger Gestures and Force Recognition Based on Wrist Electromyography and Accelerometers**. *International Conference on Intelligent Robotics and Applications*, p. 373-380, 2017

MCKINNEY, W. **Pandas: powerful Python data analysis toolkit**, 2019. Disponível em <https://pandas.pydata.org/pandas-docs/version/0.25.3/pandas.pdf>. Acesso em: 15/02/2020.

MALLERY, Charles. **Muscle Physiology**. University of Miami. Disponível em: <http://fig.cox.miami.edu/~cmallery/150/neuro/c49x38motor-unit.jpg/>. Acesso em: 07/12/2018.

MATEO, S. **Analyse cinématique de la préhension après tétraplégie : bases neurales et impact de l'imagerie motrice**. Neurosciences. Université Claude Bernard - Lyon, 2015.

MINISTÉRIO DA SAÚDE. **Diretrizes de atenção à pessoa amputada**. Secretaria de Atenção à Saúde. Departamento de Ações Programáticas Estratégicas. Brasília, DF, 2013.

MYOWARE. **User Manual**, 2015. Disponível em [www.AdvancerTechnologies.com/](http://www.AdvancerTechnologies.com/). Acesso em: 07/12/2018.

MORIMOTO, S. Y. U.; CABRAL, A. K. P. S.; SANGUINETTI, D. C. M.; FREITAS, E. S. R.; MERINO, G. S. A. D.; COSTA, J. Â. P.; COELHO, W. K.; AMARAL, D. S.

**Órteses e próteses de membro superior impressas em 3D: uma revisão integrativa.** Cadernos Brasileiros de Terapia Ocupacional, 29, 2021.

MOTOCHE, C.; BENALCÁZAR, M. E. **Real-Time Hand Gesture Recognition Based on Electromyographic Signals and Artificial Neural Networks.** 27th International Conference on Artificial Neural Networks (ICANN), 2018.

NA, D.; LI-ZHENG, L.; XIAN-JIA, Y.; QINGQING, L.; SHIH-CHING, Y. **Classification of multichannel surface-electromyography signals based on convolutional neural networks.** Journal of Industrial Information Integration, vol. 15, p. 201-206, 2019.

NAPIER, J. R. **The Prehensile Movements of the Human Hand.** Journal of Bone and Surgery, vol. 38(4), p. 902-913, Londres, 1956.

NAMIKI, A.; IMAI, Y.; ISHIKAWA, M.; KANEKO, M. **Development of a high-speed multifingered hand system and its application to catching.** Intelligent Robots and Systems (IROS) 2003. Proceedings. 2003 IEEE/RSJ International Conference on, vol. 3, 2003.

NAZEMI, A.; MALEKI, A. **Artificial Neural Network Classifier in Comparison with LDA and LS-SVM Classifiers to Recognize 52 Hand Postures and Movements.** 4th International Conference on Computer and Knowledge Engineering (ICCKE), 2014.

NAZMI, N.; ABDUL RAHMAN M.A.; YAMAMOTO, S.I.; AHMAD, S.A.; ZAMZURI, H.; MAZLAN, S.A. **A review of classification techniques of EMG signals during isotonic and isometric contractions.** Sensors, vol. 16(8), 2016.

NEUMANN. D.A. **Cinesiologia do Aparelho Musculoesquelético.** Rio de Janeiro: Guanabara Koogan, 2006.

NXP. **FRDM-KL25Z: Freedom Development Platform for Kinetis® KL14, KL15, KL24, KL25 MCUs.** Disponível em <https://www.nxp.com/products/processors-and-microcontrollers/arm-based-processors-and-mcus/kinetis-cortex-m-mcus/l->

seriesultra-low-powerm0-plus/freedom-development-platform-for-kinetis-kl14-kl15-kl24-kl25-mcus:FRDM-KL25Z/. Acesso em: 07/12/2018.

O&P ALMANAC. **Amputation data from community hospitals**. O&P Almanac, 2016.

OLIPHANT, T. E. **Guide to NumPy**. Kaneohe: Trelgol Publishing, 2006.

OLIMEX. **Shield-EKG-EMG bio-feedback shield - User's Manual**. Disponível em <https://www.olimex.com/>. Acesso em: 07/12/2018.

OPEN BIONICS. **Brunel 2.0**. Disponível em: <https://openbionicslabs.com/shop/brunel-hand/>. Acesso em: 07/12/2018.

ORTIZ-CATALAN, M.; ROUHANI, F.; BRÅNEMARK, R.; HÅKANSSON, B. **Offline accuracy: a potentially misleading metric in myoelectric pattern recognition for prosthetic control**. Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), p. 1140-1143, 2015.

OSKOEI, M.A.; HU, H. **Support vector machine-based classification scheme for myoelectric control applied to upper limb**. IEEE Transactions on Biomedical Engineering, vol. 55(8), p. 1956-1965, 2008.

OYMOTION. **GForce Gesture Armband**. Disponível em: <http://www.oymotion.com/site/>. Acesso em: 27/01/2019.

PATEL, G. K.; CASTELLINI, C.; HAHNE, J.M.; FARINA, D.; DOSEN, S. **A Classification Method for Myoelectric Control of Hand Prostheses Inspired by Muscle Coordination**. IEEE Transactions on Neural Systems and Rehabilitation Engineering (TNSRE), 2018.

PASTRE, C. M.; SALIONI, J.F.; OLIVEIRA, B.A. F. MICHELETTO, M.; NETTO JÚNIOR, J. **Fisioterapia e amputação transtibial**. Arq. Ciênc. Saúde, vol. 12(2), p. 120-124, 2005.

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, vol. 12, p. 2825-2830, 2011.

PEEMEN, M.; MESMAN, B.; CORPORAAL, C. **Speed sign detection and recognition by convolutional neural networks**. In Proceedings of the 8th International Automotive Congress, p. 162-170, 2011.

PHINYOMARK, A.; SCHEME, E. **EMG Pattern Recognition in the Era of Big Data and Deep Learning**. Big Data and Cognitive Computing, 2018.

PHINYOMARK, A.; QUAINÉ, F.; CHARBINNIER, S.; SERVIÈRE, C.; TARPIN-BERNARD, F.; LAURILLAU, Y. **EMG Feature Evaluation for Improving Myoelectric Pattern Recognition Robustness**. Expert Syst. Appl. vol. 40, p. 4832-4840, 2013.

PIBORG. **Zero Borg Triple - Getting Started**. Disponível em: <https://www.piborg.org/blog/zeroborg-getting-started/>. Acesso em: 19/03/2021.

PINTO, M. M. **Sistema Embarcado para Aquisição de Sinais Eletroencefalográficos em Tempo Real com Interface de Acesso Remoto**. Trabalho de Conclusão de Curso. Engenharia Eletrônica. Universidade do Vale do Rio dos Sinos (UNISINOS), 2021.

PIZZOLATO, S.; TAGLIAPIETRA, L.; COGNOLATO, M.; REGGIANI, M.; H. MULLER, H.; ATZORI, M. **Comparison of six electromyography acquisition setups on hand movement classification tasks**. PLoS ONE, vol. 12(10), p. 1-16, 2017.

POLOLU. **Micro Metal Gearmotors with precious metal brushes**. Disponível em: <https://www.pololu.com/file/0J949/>. Acesso em: 19/03/2021.

PRODANOV, C.; DE FREITAS, E. C. **Metodologia do Trabalho Científico: Métodos e Técnicas da Pesquisa e do Trabalho Acadêmico**. 2. ed. Editora Feevale, 2013. Disponível em: <http://www.feevale.br/Comum/midias/8807f05a-14d0-4d5b-b1ad-1538f3aef538/E-book%20Metodologia%20do%20Trabalho%20Cientifico>

.pdf/. Acesso em: 19/01/2019.

PYTHON, 2019. **Python 3.7.6 documentation**. Disponível em <https://docs.python.org/3.7/>. Acesso em 20/01/2019.

**Raspberry Pi**. Disponível em: <https://www.raspberrypi.org/>. Acesso em: 07/12/2018.

RAURALE, S. A.; McALLISTER, J.; DEL RINCON, J. M. **Real-Time Embedded EMG Signal Analysis for Wrist-Hand Pose Identification**. IEEE Transactions on Signal Processing, vol. 68, p. 2713 - 2723, 2020.

RAZZA, B. M.; PASCHOARELLI, L. C. **Avaliação de forças de preensão digital: parâmetros para o design ergonômico de produtos**. Design e ergonomia: aspectos tecnológicos. Editora UNESP, 2009.

REHMAN, M. Z.; GILANI, S. O.; WARIS, A.; NIAZI, I. K.; KAMAVUAKO, E. N. **A novel approach for classification of hand movements using surface EMG signals**. IEEE International Symposium on Signal Processing and Information Technology, 2017.

RIBEIRO, E. S. **Acionamento de Mão Protética por Comando de Voz**. Trabalho de Conclusão de Curso. Engenharia Elétrica. Universidade do Vale do Rio dos Sinos (UNISINOS), 2019.

ROBINSON, C.P.; MENG, Q.; LI, B.; PAIN, M.T.G. **Pattern Classification of Hand Movements using Time Domain Features of Electromyography**. 4th International Conference on Movement Computing, 2017.

ROSE, W. **Electromyogram Analysis (notes)**. In **Mathematics and Signal Processing for Biomechanics**, 2019. Disponível em: <https://www1.udel.edu/biology/rosewc/kaap686/notes/EMG%20analysis.pdf>. Acesso em: 27/12/2018.

RUBO, F. **Sistema de Processamento de Sinais EMG para Controle de Prótese de Mão**. Trabalho de Conclusão de Curso. Engenharia Eletrônica. Universidade do Vale do Rio dos Sinos (UNISINOS), 2020.

SANCHEZ-VELASCO, L.; ARIAS-MONTIEL, M.; GUZMAN-RAMIREZ, E.; LUGO-GONZALEZ, E. **A Low-Cost EMG-Controlled Anthropomorphic Robotic Hand for Power and Precision Grasp**. Biocybernetics and Biomedical Engineering, vol. 40, p. 221- 237, 2020.

SANTOS, A. O. **Projeto e Desenvolvimento de um Protótipo para Aquisição de Multisinais EMG**. Trabalho de Conclusão de Curso. Engenharia de Controle e Automação Industrial. Universidade do Vale do Rio dos Sinos (UNISINOS), 2021.

SATTAR, N. Y.; SYED, U. A.; MUHAMMAD, S.; KAUSAR, Z. **Real-Time EMG Signal Processing with Implementation of PID Control for Upper-Limb Prosthesis**. IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM), 2019.

SCHEME, E.; ENGLEHART, K. **Electromyogram Pattern Recognition for Control of Powered Upper-Limb Prostheses: State of the Art and Challenges for Clinical use**. Journal of Rehabilitation Research & Development, vol. 48 (6), p. 643-660, 2011.

SENIAM. **Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles**. Disponível em: <http://www.seniam.org/>. Acesso em: 05/05/2020.

SHIM, H.M.; LEE, S. **Multi-Channel Electromyography Pattern Classification Using Deep Belief Networks for Enhanced User Experience**. J. Cent. South Univ., vol. 22, p. 1801-1808, 2015.

SIH/SUS. **Procedimentos Hospitalares do SUS**. Sistema de Informações Hospitalares do Sistema Único de Saúde (SIH/SUS). Disponível em: <http://tabnet.datasus.gov.br/cgi/tabcgi.exe?sih/cnv/qiuf.def>. Acesso em: 07/06/2021.

SILVA, I. N., SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. São Paulo, Artliber, 2010.

SILVA, H. P., GUERREIRO, J., LOURENÇO, A., FRED, A. L.N. **Bitalino: A Novel Hardware Framework for Physiological Computing**. Conference: International Conference on Physiological Computing Systems (PhyCS), 2014.

SOLNIK, S.; RIDER, P.; STEINWEG, K.; DEVITA, K. P.; HORTOBÁGYI, T. **Teager-Kaiser energy operator signal conditioning improves EMG onset detection.** *European Journal of Applied Physiology*, vol. 110 (3), p. 489-498, 2010.

SÖRNMO, L.; LAGUNA, P. **Bioelectrical Signal Processing in Cardiac and Neurological Applications.** Amsterdam: Academic Press. 2005.

SOUZA, J. O. O.; BLOEDOW, M. D.; RUBO, F.; FIGUEIREDO, R. M.; PESSIN, G.; RIGO, S. J. **Investigation of Different Approaches to Real-Time Control of Prosthetic Hands with Electromyography Signals.** *IEEE Sensors*, 2021.

SOUZA, J. O. O.; SANTOS, J. V. C. ; PESSIN, G. ; FIGUEIREDO, R. M. **Real-time hand prosthesis biomimetic movement based on electromyography sensory signals treatment and sensors fusion.** In: 27th International Conference on Artificial Neural Networks, 2018, Rhodes, Grécia. ENNS, 2018.

SRIVASTAVA, N.; HINTON, G.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. **Dropout: A Simple Way to Prevent Neural Networks from Overfitting.** *Journal of Machine Learning Research*, vol. 15, 2014.

STOPPA, M. H.; CARVALHO, J. C. M. **Modelagem cinemática, simulação de movimento, construção e controle de prótese de mão para tarefas de manipulação,** p. 183-208. In: **Matemática aplicada à indústria: problemas e métodos de solução.** São Paulo: Blucher, 2016.

THARWAT, A.; GABER, T.; IBRAHIM, A.; HASSANIEN, A. E. **Linear Discriminant Analysis: A Detailed Tutorial.** *AI Communications*, vol. 30, p. 169-190, 2017.

TASKA. **Taska Prosthetics Technical Information.** Disponível em: <http://www.taskaprosthetics.com/>. Acesso em: 07/12/2018.

TENSORFLOW LITE, 2019. **TensorFlow Lite Guide.** Disponível em <https://www.tensorflow.org/lite/>. Acesso em: 21/02/2019.

TESHIGAWARA, S., ISHIKAWA, M., SHIMOJO, M. **Study of High Speed and High Sensitivity Slip Sensor Characteristic of conductive material**. SICE Annual Conference 2008, The University Electro-Communications, Japan, 2008.

**Texas Assistive Devices**. Disponível em: <https://opedge.com/ShowcaseProducts/texas-assistive-devices-tad/texas-assistive-devices-tad/>. Acesso em: 26/12/2018.

THARWAT, A.; GABER, T.; IBRAHIM, A.; HASSANIEN, A. E. **Linear Discriminant Analysis: A Detailed Tutorial**. AI Communications, vol. 30, p. 169-190, 2017.

TIAN, L.; THALMANN, N. M.; THALMANN, D.; ZHENG, J. **The Making of a 3DPrinted, Cable-Driven, Single-Model, Lightweight Humanoid Robotic Hand**. Frontiers in Robotics and AI, 2017.

TOMMASI, T.; ORABONA, F.; CASTELLINI, C.; CAPUTO, B. **Improving Control of Dexterous Hand Prostheses using Adaptive Learning**. IEEE Transactions on Robotics, vol. 29(1), 2013.

TOUCH BIONICS. **i-Limb Quantum Technical Information**. Disponível em: <http://touchbionics.com/products/active-prostheses/i-limb-quantum/>. Acesso em: 26/12/2018.

VEER, K.; SHARMA, T. **A novel feature extraction for robust EMG pattern recognition**. Journal of Medical Engineering & Technology, 2016.

WANG, H.; RAJ, B. **On the Origin of Deep Learning**. ArXiv e-prints, 2017. Disponível em <https://arxiv.org/pdf/1702.07800.pdf/>. Acesso em: 26/12/2018.

WAZLAWICK, R. **Metodologia de Pesquisa para Ciência da Computação**. 2. ed. Rio de Janeiro, Elsevier, 2014.

WEINER, P.; NEEF, C.; SHIBATA, Y.; NAKAMURA, T. **An Embedded, Multi-Modal Sensor System for Scalable Robotic and Prosthetic Hand Fingers**. Sensors, vol. 20(1):101, 2020.

WORKCOMPWIRE. **Guest Post: Controlling the Costs of Myoelectric Prosthetics.** Disponível em <https://www.workcompwire.com/2018/11/guest-post-controlling-the-costs-of-myoelectric-prosthetics/>. Acesso em: 21/07/2021.

WRIGHT, F. V.; HUBBARD, S.; JUTAI, J.; NAUMANN, S. **The prosthetic upper extremity functional index: development and reliability testing of a new functional status questionnaire for children who use upper extremity prostheses.** Journal of Hand Therapy, Elsevier, vol. 14(2), p. 91-104, 2001.

YAO, B.; PENG, Y.; ZHANG, Y.; ZHOU, P.; PU, J. **The influence of common component on myoelectric pattern recognition.** Journal of International Medical Research, vol. 48(3), 2020.

YOUNG, A.J.; SMITH, L.H. ROUSE, E.J. HARGROVE, L.J. **Classification of Simultaneous Movements Using Surface EMG Pattern Recognition.** IEEE Transactions on Biomedical Engineering, vol. 60(5), p. 1250-1258, 2013.

ZHAI, X.; JELFS, B.; CHAN, R. H. M.; TIN, C. **Self-Recalibrating Surface EMG Pattern Recognition for Neuroprosthesis Control based on Convolutional Neural Network.** Frontiers in Neuroscience, vol. 11, 2017.

ZHANG, Z.; YANG, K.; QIAN, J.; ZHANG, L. **Real-Time Surface EMG Pattern Recognition for Hand Gestures Based on an Artificial Neural Network.** Sensors, vol. 19(14), 3170, 2019.

ZHANG, D.; ZHAO, X.; HAN, J.; ZHAO, Y. **A Comparative Study on PCA and LDA Based EMG Pattern Recognition for Anthropomorphic Robotic Hand.** IEEE International Conference on Robotics & Automation (ICRA), 2014.

ZHOU, T.; OMISORE, O. M.; DU, W.; WANG, L.; ZHANG, Y. **Adapting Random Forest Classifier Based on Single and Multiple Features for Surface Electromyography Signal Recognition.** 12th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), 2019.

## APÊNDICE A - PLATAFORMAS PARA AQUISIÇÃO DE SINAIS EMG

A tabela 15 apresenta a análise comparativa utilizada para a escolha do sistema, levando em consideração aspectos como peso, dimensões, comunicação, número de eletrodos e custo. A figura 59 apresenta uma imagem de cada plataforma.

Tabela 15 - Comparação entre as plataformas de aquisição de biosinais

<b>Descrição</b>	<b>BITalino</b>	<b>gForce</b>	<b>e-Health</b>	<b>MyoWare</b>	<b>Olimex EKG-EMG</b>
Arquitetura	ATmega328P	ARM Cortex M4	ATmega328P (placa adicional)	ATmega328P (placa adicional)	ATmega328P (placa adicional)
Amplificador	AD8232	N/D	N/D	AD8221	INA321EA
Firmware específico	+++	+++	++	+	N/D

Número de canais EMG	4	8	1	6 (empilhável)	1
Entradas Analógicas	4 (10 bits) 2 (6 bits)	8 (16 bits)	-	-	-
Protocolos de Comunicação	Bluetooth	Bluetooth	Bluetooth, Zigbee, Wi-Fi, GPRS (externos)	Bluetooth (externo)	Bluetooth (externo)
Dimensões (mm)	70 x 62	85 x 70	85,6 x 54	52,3 x 20,7	50,8 x 50,8
Peso (g)	30	93	N/D	7,5	50
Custo (US\$)	250,00	1.000,00	650,00	38,00	16,00

Fonte: Cooking-hacks (2018), OYMotion (2019), MyoWare (2015), Olimex (2018) e Silva *et al.* (2014).


Figura 59 - Plataformas de aquisição de sinais EMG



(a) MyoWare



(b) Olimex EKG-EMG



(c) e-Health



(d) gForce



(e) BITalino

Fonte: MyoWare (2015), Olimex (2018), Cooking-Hacks (2018), OYMotion (2019) e Silva *et al.* (2014).

## APÊNDICE B - PLATAFORMAS DE PROTOTIPAGEM RÁPIDA

A tabela 16 resume algumas especificações das cinco plataformas citadas anteriormente e a figura 60 apresenta uma imagem de cada plataforma.

Tabela 16 - Comparação entre as plataformas de prototipação

Descrição	Arduino	Beagle	Freedom	Intel Galileo	Raspberry Pi
Modelo	Uno	Pocket	FRDM-KL25Z	Gen 2	B+
Arquitetura	8 bits	32 bits	32 bits	32 bits	64 bits
Frequência de operação	16 MHz	1 GHz	48 MHz	400 MHz	1,4 GHz
I/Os digitais	14	44	66	14	40



I/Os analógicos	6 (10 bits)	8	6 (16 bits)	6 (12 bits)	8 (17 bits) (externo)
Memória RAM	2 kB	512 MB	16 kB	256 MB	1 GB
Dimensões (mm)	68,6 x 53,3	56 x 35	81 x 53,3	123,8 x 72	85 x 56
Custo (US\$)	20,50	27,36	17,22	95,95	35,00

Fonte: Arduino (2018), Beagle (2018), Intel (2018), NXP (2018), Raspberry Pi (2018) e Digikey (2019).

Figura 60 - Plataformas de prototipagem



(a) Intel Galileo



(b) Beagle



(c) Freedom



(d) Arduino



(e) Raspberry Pi

Fonte: Adaptado de Arduino (2018), Beagle (2018), Intel (2018), NXP (2018) e Raspberry Pi (2018).

## APÊNDICE C - TERMO DE CONSENTIMENTO LIVRE ESCLARECIDO

Prezado (a) Senhor (a),

O(a) Sr(a). está sendo convidado (a) a participar da pesquisa: “Investigação de métodos para controle de prótese de mão de baixo custo através da classificação de sinais via Aprendizado de Máquina” que tem por objetivo implementar um sistema de controle de prótese baseado em reconhecimento automático de padrões de movimentos mão-braço.

Sua participação no estudo consistirá em utilizar um bracelete de sensores e realizar uma sequência de movimentos para a aquisição de sinais bioelétricos (sinais gerados pelo próprio corpo humano) e também na manipulação de uma prótese de mão. Antes do início da aquisição dos sinais, o(a) senhor(a) receberá uma explicação (de forma escrita e oral) do experimento de aquisição. A aquisição dos sinais bioelétricos terá uma duração de mais ou menos trinta minutos.

O evento será dividido em 2 sessões: Na primeira sessão serão realizados os movimentos de mão e na segunda sessão os movimentos para aperto de objetos. Durante as sessões, o(a) senhor(a) realizará primeiro uma sequência de treinamento que envolve três repetições dos movimentos para se acostumar com o protocolo. Após, será solicitado ao(a) senhor(a) a realização de 6 repetições de cada movimento, iniciando na posição relaxada. Cada repetição de movimento será realizada por 5 s de contração, intercalados com pausas de 5 s para permitir ao senhor(a) descansar, totalizando 300 s para a sessão 1 e 300 s para a sessão 2.

Os procedimentos adotados nesta pesquisa obedecem aos Critérios da Ética em Pesquisa com Seres Humanos conforme Resolução nº. 466/2012 do Conselho Nacional de Saúde.

Os protocolos para a aquisição dos sinais e manipulação da prótese de mão geram ações repetitivas e podem trazer algum desconforto para o(a) senhor(a), sendo que os procedimentos se justificam, pois gerarão informações que serão úteis para o desenvolvimento de um controle eletrônico de código aberto e na obtenção de mais funções para as próteses de mão, trazendo desta forma um impacto positivo à sociedade. Os resultados deste projeto devem beneficiar indivíduos que apresentam problemas graves para os quais alternativas viáveis de reabilitação são extremamente importantes.

As sessões possuem riscos mínimos pois, o(a) senhor(a) permanecerá sentado(a) durante os experimentos. Mas caso tenha algum desconforto, o(a) senhor(a) tem a liberdade de interromper a qualquer momento, sem nenhum prejuízo para seu atendimento. O(a) Sr(a). tem a liberdade de não participar da pesquisa ou retirar seu consentimento a qualquer momento, mesmo após o início da entrevista/coleta de dados, sem qualquer prejuízo. Está assegurada a garantia do sigilo das suas informações.

Se houver algum problema relacionado com a pesquisa, será acionado o ramal de emergência 234, onde a universidade disponibiliza serviços de ambulância. O(a) senhora também pode ser encaminhado(a) para a enfermaria da Universidade onde será atendido(a)/acompanhado(a) e poderá ser encaminhado(a) para o serviço de referência do seu município para acompanhamento.

O(a) Sr(a). não terá nenhuma despesa e não há compensação financeira relacionada à sua participação na pesquisa. Caso tenha alguma dúvida sobre a pesquisa o (a) Sr(a). poderá entrar em contato com o coordenador responsável pelo estudo: João Olegário de Oliveira de Souza, que pode ser localizado na sala C02 106 (telefone 51-99977-8555) das 8h às 12h ou pelo email joaoolegario@yahoo.com.br.

O Comitê de Ética em Pesquisa do Instituto de Saúde - CEPIS, também poderá ser consultado caso o(a) Sr(a). tenha alguma consideração ou dúvida sobre a ÉTICA da pesquisa pelo telefone (11) 3116-8597 ou pelo email cepis@isaude.sp.gov.br.

Este termo será assinado em duas vias, pelo(a) senhor(a) e pelo responsável pela pesquisa, ficando uma via em seu poder.

Concordo voluntariamente em participar deste estudo.

\_\_\_\_\_ / \_\_\_\_ / \_\_\_\_

Assinatura do(a) entrevistado(a)

\_\_\_\_\_ / \_\_\_\_ / \_\_\_\_

Assinatura do responsável pelo estudo.

## APÊNDICE D - ANAMNESE

### Identificação da(o) voluntária(o)

Nome:

Idade:

Altura:

Peso:

Gênero:

Cor:

Naturalidade:

Estado Civil:

Escolaridade:


Profissão:		
Lateralidade (destro ou canhoto):		
Patologia?	Qual(is):	
Procedimento cirúrgico no(s) membro(s) superior(es)?		Idade do procedimento:
Toma medicação?	Qual(is):	
Pratica esporte?	Qual(is):	Quantas vezes por semana:

### Contato da(o) voluntária(o)


Endereço:	
Número:	Complemento:
Bairro:	CEP:
Cidade:	Estado:
Telefone:	
E-mail:	

## APÊNDICE E - MATRIZES DE CONFUSÃO (NINAPRO)

Figura 61 - Matriz de confusão do classificador MLP para 50 classes (*dataset* DB2)




(a) melhor cenário (sujeito 5)




(b) pior cenário (sujeito 3)

Fonte: Elaborado pelo autor (2021).

Figura 62 - Matriz de confusão do classificador RF para 50 classes (dataset DB2)





(a) melhor cenário (sujeito 5)



(b) pior cenário (sujeito 4)

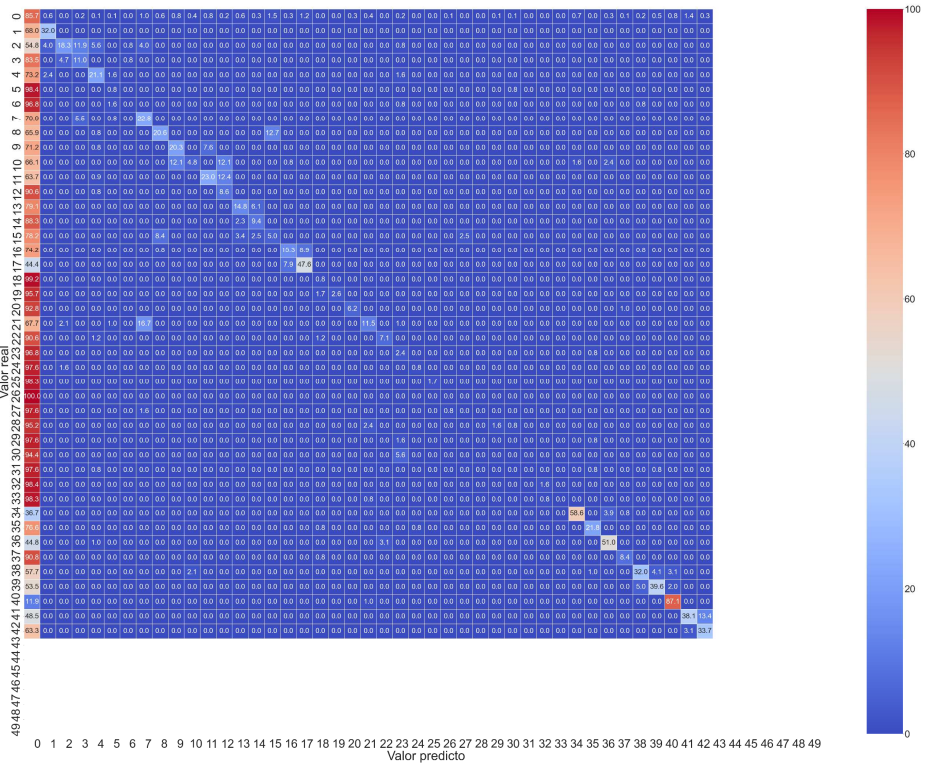

Fonte: Elaborado pelo autor (2021).

Figura 63 - Matriz de confusão do classificador MLP para 50 classes (dataset DB3)



Fonte: Elaborado pelo autor (2021).

Figura 64 - Matriz de confusão do classificador RF para 50 classes (dataset DB3)



Fonte: Elaborado pelo autor (2021).



## APÊNDICE F - CUSTO DO PROTÓTIPO

Tabela 17 - Orçamento dos materiais para construção do protótipo

Item	Descrição	Valor Unitário (R\$)	Quantidade	Valor Total (R\$)
1	Plataforma Raspberry Pi 3 modelo B+	300,00	1	300,00
2	Placa de desenvolvimento/módulo ESP32	50,00	1	50,00
3	Servomotor modelo MG995 (Tower Pro)	50,00	5	250,00
4	Sistema de aquisição EMG modelo MuscleBIT (BITalino)	1.400,00	2	2.800,00
5	Serviços de prototipagem (peças em ABS)	250,00	1	250,00
6	Componentes eletrônicos diversos (resistores, capacitores, transistores)	50,00	1	50,00
7	Componentes diversos (fios de nylon, fitas elásticas)	60,00	1	60,00
8	Matriz de contato (custo similar a manufatura de placa de circuito impresso)	40,00	1	40,00
<b>TOTAL (R\$)</b>				<b>3.800,00</b>

Fonte: Elaborado pelo autor (2021)

## **APÊNDICE G - ARTIGO SOBRE PROJETO DE HARDWARE E SOFTWARE DE SISTEMA PARA CONTROLE DE PRÓTESE DE MÃO**

**Título:** Real-Time Hand Prosthesis Biomimetic Movement Based on Electromyography Sensory Signals Treatment and Sensors Fusion

**Autores:** SOUZA, J. O. O.; SANTOS, J. V. C.; FIGUEIREDO, R. M.; PESSIN, G.

**Conferência/Periódico:** International Conference on Artificial Neural Networks (ICANN)

**Ano:** 2018

**Abstract:** The hand of the human being is a very sophisticated and useful instrument, being essential for all types of tasks, from delicate manipulations and of high precision, to tasks that require a lot of force. For a long time researchers have been studying the biomechanics of the human hand, to reproduce it in robotic hands to be used as a prosthesis in humans, in the replacement of limbs lost or used in robots. In this study, we present the implementation (electronics project, acquisition, treatment, processing and control) of different sensors in the control of prostheses. The sensors studied and implemented are: inertial, electromyography (EMG), force and slip. The tests showed reasonable results due to sliding and dropping of some objects. These sensors will be used in a more complex system that will approach the fusion of sensors through Artificial Neural Networks (ANNs) and new tests should be performed for different scenarios.

**APÊNDICE H - ARTIGO SOBRE INVESTIGAÇÃO DE MÉTODOS E RECURSOS  
PARA CONTROLE DE PRÓTESES DE MÃO UTILIZANDO APRENDIZADO DE  
MÁQUINA NA CLASSIFICAÇÃO DE SINAIS EMG**

**Título:** Investigation of Different Approaches to Real-Time Control of Prosthetic Hands with Electromyography Signals

**Autores:** SOUZA, J. O. O.; BLOEDOW, M. D.; RUBO, F.; FIGUEIREDO, R. M.; PESSIN, G.; RIGO, S. J.

**Conferência/Periódico:** IEEE Sensors

**Ano:** 2021

**Abstract:** In this article, we describe a real-time system for prosthetic hands control. The system architecture includes the integration of the electromyographic (EMG) signal acquisition devices, platform for the implementation of the real-time classifier, sensors for the detection of object slip after grasp and the open source hand prosthesis. Three databases were used to evaluate the implemented classifiers: a database with EMG data from local volunteers and NinaPro DB2 and DB3 databases that include electromyography and accelerometry (ACC) data acquisitions. A Multilayer Perceptron (MLP) classifier was implemented on a platform for rapid prototyping (Raspberry Pi 3 model B+) and generated responses in real-time (11 ms) with average accuracy of 96.30% for 11 hand and wrist gestures/movements.