



UNIVERSIDADE ESTADUAL PAULISTA
JÚLIO DE MESQUITA FILHO
FACULDADE DE ENGENHARIA
CÂMPUS DE ILHA SOLTEIRA - SP

RICARDO TAONI XAVIER

**Classificação com *Deep Learning* de Sinais
de uma Interface Neural HDsEMG para
Acionamento de Neuropróteses Transradiais**

Ilha Solteira

2021

RICARDO TAONI XAVIER

**Classificação com *Deep Learning* de Sinais de uma
Interface Neural HDsEMG para Acionamento de
Neuropróteses Transradiais**

Tese apresentada à Faculdade de Engenharia -
UNESP - Câmpus de Ilha Solteira, Programa
de Pós-graduação em Engenharia Elétrica,
como requisito para obtenção do título de
Doutor em Engenharia Elétrica.

Área de Conhecimento: Automação

Orientador: Prof. Dr. Aparecido Augusto de
Carvalho

Ilha Solteira

2021

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

X3c Xavier, Ricardo Taoni.
Classificação com *Deep Learning* de sinais de uma interface neural HDsEMG para acionamento de neuropróteses transradiais / Ricardo Taoni Xavier. -- Ilha Solteira: [s.n.], 2021
135 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2021

Orientador: Aparecido Augusto de Carvalho
Inclui bibliografia

1. Amputação membro superior. 2. Neuropróteses transradiais. 3. HDsEMG. 4. *Transfer learning*. 5. *Deep leaning*. 6. Mãos robóticas.


Raiane da Silva Santos

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: Classificação com *Deep Learning* de Sinais de uma Interface Neural HDsEMG para Acionamento de Neuropróteses Transradiais

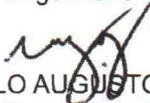
AUTOR: RICARDO TAONI XAVIER

ORIENTADOR: APARECIDO AUGUSTO DE CARVALHO

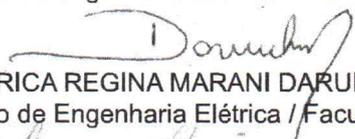
Aprovado como parte das exigências para obtenção do Título de Doutor em ENGENHARIA ELÉTRICA, área: Automação pela Comissão Examinadora:



Prof. Dr. APARECIDO AUGUSTO DE CARVALHO (Participação Virtual)
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP



Prof. Dr. MARCELO AUGUSTO ASSUNÇÃO SANCHES (Participação Virtual)
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP



Profa. Dra. ERICA REGINA MARANI DARUICHI MACHADO (Participação Virtual)
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP



Prof. Dr. MAURO CONTI PEREIRA (Participação Virtual)
Departamento de Eletrotécnica / Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso do Sul - IFMS



Prof. Dr. JOSIVALDO GODOY DA SILVA (Participação Virtual)
Centro de Tecnologia / Universidade Federal de Mato Grosso do Sul - UFMS

Ilha Solteira, 13 de agosto de 2021

À minha família.

À minha mãe Maria Helena Taoni Xavier,

À meu pai Paulo Xavier Neto,

In Memoriam.

*Definitivamente à primeira pessoa que me reconheceu como um ser humano capaz,
me dando a oportunidade de seguir este caminho...*

Profa. Ms. Maria Aparecida Laurindo Polizelle

AGRADECIMENTOS

Gostaria de agradecer primeiramente à minha esposa Rafaela da Costa, são poucas as pessoas que compartilham de si para fortalecer, lutar e conquistar de mãos dadas, sua força, garra e profissionalismo me inspiram, dedico o futuro desta jornada á você. *"sonho que se sonha junto é realidade"*, Raul Seixas. Aos meus sogros Regina e Osvaldinei da Costa, meus cunhados Natalia e Caio Martins e meus sobrinhos que deram de si para me acolher, expresso minha eterna gratidão. Agradecimento especial para minhas filhas Julia e Helena da Costa que fazem do meu mundo a certeza de onde quero viver e estar, não poderia chegar até aqui sem os ensinamentos diários de vocês.

Agradeço às minhas irmãs Thays e Priscilla Taoni por me ensinarem todos os dias sobre o verdadeiro amor, e por me ensinarem hoje a como caminhar sob os passos de quem um dia sonhou e nos norteou para chegarmos até aqui. Ao meu cunhado Lucas Pereira por me ensinar sobre valores e determinação.

Aos meus pais/tios Luiz e Elisa Taoni por sempre nos acolherem como os próprios filhos, e com a lembrança por toda vida de que quando criei asas pela primeira vez, foram vocês que estavam lá me ajudando e me ensinando a voar. Aos meus queridos tios Sueli Tuono e Bernard Migy pelo acolhimento fraterno e pelo amor que nunca sonhei encontrar á milhares de quilômetros. Em seus nomes agradeço à cada familiar que me acolheu durante essa jornada.

Agradeço imensamente à família Laurindo Polizelle, por todos esses anos de convívio e aprendizado. A fraternidade, hospitalidade e acolhimento de corpo e alma de vocês me transformam todos os dias.

Agradeço ao Gilberto Brito por ter me dado tantas referências em minha vida por todos os suportes, conhecimentos e ensinamentos que me proporcionou. Foram chaves para me tornar o que sou hoje, gratidão por ser este amigo, companheiro, irmão e pai.

Ao meu orientador de doutoramento Aparecido Augusto de Carvalho por ter acreditado que este caminho seria possível e por não ter medido esforços para contribuir com o meu desenvolvimento pessoal, profissional e principalmente humano. O senhor se tornou referência sobre o verdadeiro significado de Humanidade. E se hoje posso constituir família e ter a certeza de que o futuro me proporcionará grandes e nobres desafios foi por que um dia também confiou e acreditou em mim, minha eterna gratidão.

Agradeço também ao meu orientador do doutoramento com período sanduíche Silvestro Micera pelo acolhimento e pelas práticas científicas compartilhadas. Em seu nome agradeço a todos os pesquisadores do TNELab EPFL dos quais tive a honra de trabalhar. À Solaiman Shokur por todos os ensinamentos e orientações nesta jornada. Aos queridos Martine Challand e David Desscan por tornarem este sonho possível.

Ao Yann Dixon por ter me ensinado o verdadeiro significado de amizade e companheirismo. Por ter sido um irmão/pai durante toda minha jornada no exterior, à você e sua família que sempre me acolheram tão bem. Eu sempre vou estar torcendo pelo melhor.

Agradeço à UNESP câmpus de Ilha Solteira por todos esses anos de boas práticas e grandes experiências. Ao Aderson Anhussi, Deoclécio Mitsuiti, Dilsa Ribeiro, Everaldo Moraes, Márcia Nagamachi, Mário Junior, Valdemir Chaves, Valéria Pereira, Wendel Jordão. Ao LIEB um novo lar que me acolheu por anos e me ensinou minha vocação, aos companheiros Aurasil Garcia, Caroline Meireles, Fábio Boris, Luan Vogás, Maria e Marcus Jorgetto, Marcelo Sanches, Mariana Andreazzi, Mateus Urban, Paulo Codinhoto, Rafael Araújo, Thiago Pentiado, Weslin Savaris, Wilker Bernardo pela amizade, companheirismo e construções nestes anos junto à família LIEB.

Ao Fabian Castro irmão que a vida me deu, pela fraternidade e comprometimento. Ao Jorge Blanco pela amizade e por todas as experiências vividas.

Ao pesquisadores brasileiros na Suíça Luiz Manfle, Vanessa Mucivuna e Fernando Sá por terem me ensinado a olhar o mundo sob uma nova perspectiva e pelas trajetórias e conhecimentos dos quais tive a honra de compartilhar.

Aos Professores António Pádua, Carlos Alves, Claudio Carvalho, Claudio Kitano, Dionízio Paschoareli, Erica Daruichi, Edvaldo Assunção, Hermes e Sueli Aquino, Júlio Borges, Marcelo Machado, Nivaldo Urzulin e Ricardo Tokio. Por sempre me tratarem com reconhecimento. Por muitas vezes, fatores adversos da vida me fizeram querer desistir e a competência e humanidade de cada um de vocês me fizeram continuar, gratidão.

A presente tese foi realizada com apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001 e com apoio da Bertarelli Foundation (FB).

À todos que de alguma forma compartilharam deste sonho comigo.

Gratidão à todos.

"O conhecimento emerge apenas através da invenção e da reinvenção, através da inquietante, impaciente, contínua e esperançosa investigação que os seres humanos buscam no mundo, com o mundo e uns com os outros."

(Paulo Freire)

"Somewhere, something incredible is waiting to be known."

(Carl Sagan)

"Man's greatest asset is the unsettled mind"

(Isaac Asimov)

RESUMO

Introdução: a amputação do membro superior afeta diretamente o desenvolvimento pessoal, limitando atividades da vida diária e diminuindo a qualidade de vida. Implementar próteses de membros superiores para restaurar e reabilitar funções e capacidades perdidas é um desafio de muitas pesquisas ao redor do mundo. Hoje, próteses comerciais de mãos são controladas intuitivamente por contrações musculares voluntárias. Entretanto, mesmo com a modernização e a qualidade destes sistemas protéticos o acionamento continua sendo um dos principais desafios. A integração entre o acionamento eletromiográfico e o feedback neural tem apresentando resultados consistentes. As neuropróteses são capazes de fornecer ao usuário uma gama de informações, seja para os movimentos realizados pela prótese ou para sensações somatossensoriais artificiais. Esses novos conceitos precisam de técnicas avançadas em inteligência artificial para garantir ao usuário segurança, autonomia e uma interação próxima a realidade. O objetivo deste trabalho foi comparar as classificações entre dois modelos de redes neurais convolucionais profundas, as *Deep Learning* utilizando métodos de *Transfer Learning* para o reconhecimento de movimentos por contrações musculares no acionamento de neuropróteses transradiais. **Métodos:** os modelos escolhidos foram a *Deep Learning* desenvolvida por pesquisadores da *Google* (GoogLeNet) e a *Deep Learning Visual Geometry Group* de 19 camadas (VGG19) desenvolvida por pesquisadores da Universidade de *Oxford*. O banco de dados utilizado neste trabalho é resultado da implementação de uma interface neural multicanal com sinais eletromiográficos de superfície de alta densidade (HDsEMG). Contendo 64 canais de aquisição com eletrodos monopolares e uma estrutura modular vestível para o antebraço. Estes sinais foram processados e convertidos em escalogramas, representações no domínio do tempo e da frequência utilizando Transformadas de *Wavelets* Contínuas e Discretas e também recursos para extração de características e reconhecimento de padrões, destacando-se *Root mean square*, *Windows Length* e *Slide Windows* como métodos de janelamento e sobreposição, o *overlapping* e um algoritmo para extração de classes dos sinais, o *labelling*. Nas classificações foram aplicadas nove classes para o treinamento originados de oito movimentos da mão e do punho mais a classe de repouso. Os modelos receberam a aplicação de quatro métricas de validação para garantir a eficiência dos treinamentos. Sendo elas, a acurácia, a sensibilidade, a especificidade, a seletividade e o *F1 Score*. **Resultados:** foi gerado um banco de dados com imagens de escalogramas para o treinamento dos modelos investigados, apresentando acurácia acima de 70%, o modelo GoogLeNet apresentou acurácia máxima de 79,46% e a modelo VGG19 apresentou acurácia máxima de 85,66%. **Conclusão:** esta tese fornece evidências sobre a eficiência de classificadores *deep learning* com os modelos GoogLeNet e VGG19, onde demonstraram seu potencial para aumentar a capacidade funcional das neuropróteses de membros superiores. A estratégia de utilizar a interface neural HDsEMG com os modelos propostos melhorou efetivamente os resultados. Essas descobertas abrem perspectivas promissoras para aplicações em neuropróteses transradiais.

Palavras-chave – Amputação Membro Superior. Neuropróteses Transradiais. HDsEMG. *Transfer Learning*. *Deep Learning*. Mãos Robóticas.

ABSTRACT

Introduction: upper limb amputation directly affects personal development, limiting activities of daily living and decreasing quality of life. Implementing upper limb prostheses to restore and rehabilitate lost functions and capabilities is a challenge for many researches around the world. Today, commercial hand prostheses are intuitively controlled by voluntary muscle contractions. However, even with the modernization and quality of these prosthetic systems, the activation remains one of the main challenges. The integration between electromyographic triggering and neural feedback has shown consistent results. Neuroprostheses are able to provide the user with a range of information, whether for the movements performed by the prosthesis or for artificial somatosensory sensations. These new concepts need advanced techniques in artificial intelligence to guarantee the user's safety, autonomy and an interaction close to reality. The objective of this work was to compare the classification between two deep convolutional neural network models, the Deep Learning using the Transfer Learning method for the recognition of muscle contractions in the activation of transradial neuroprostheses. **Methods:** the chosen models were the Deep Learning developed by Google researchers (GoogLeNet) and the 19-layer Deep Learning Visual Geometry Group (VGG19) developed by researchers from the University of Oxford. The database used in this work is the result of the implementation of a multichannel neural interface with high density surface electromyographic signals (HDsEMG). Containing 64 acquisition channels with monopolar electrodes and a wearable modular structure for the forearm. These signals were processed and converted into scalograms, time and frequency domain representations using Continuous and Discrete Wavelet Transforms, as well as features for feature extraction and pattern recognition, highlighting Root mean square, Windows Length and Slide Windows as windowing and overlapping methods, overlapping and an algorithm for extracting classes from signals, labeling. In the classifications, nine classes for training originated from eight movements of the hand and wrist plus the rest class were applied. The models received the application of four validation metrics to ensure training efficiency. These are the accuracy, sensitivity, specificity, selectivity and the F1 Score. **Results:** a database with scalogram images was generated for the training of the investigated models, presenting an accuracy above 70%, the GoogLeNet model presented a maximum accuracy of 79.46% and the VGG19 model presented maximum accuracy of 85.66%. **Conclusion:** this thesis provides evidence on the efficiency of deep learning classifiers with the GoogLeNet and VGG19 models, where they demonstrated their potential to increase the functional capacity of upper limb neprostheses. The strategy of using the HDsEMG neural interface with the proposed models effectively improved the results. These discoveries open promising prospects for applications in transradial neuroprostheses.

Keywords – Upper Limb Amputation. Transradial Neuroprostheses. HDsEMG. Transfer Learning. Deep Learning. Robotic Hands.

LISTA DE FIGURAS

Figura 1 – Ilustração das mãos realizando uma preensão, movimento para manipular grãos e líquidos.	22
Figura 2 – Ilustração do membro superior para identificar suas divisões em braço, antebraço e mão.	24
Figura 3 – Representação dos níveis de amputação dos membros superiores.	27
Figura 4 – Diagrama com os tipos de Mãos Robóticas: Mãos Robóticas Protéticas e Pesquisas de Mãos Robóticas.	29
Figura 5 – Representação das principais mãos robóticas ao longo da história.	31
Figura 6 – Ilustração dos músculos superficiais do antebraço.	33
Figura 7 – Gráfico com os tipos de eletrodos para interfaces PNS.	47
Figura 8 – Gráfico com conceito de controle bidirecional para mãos robóticas.	48
Figura 9 – Decomposição DWT de quarta ordem.	64
Figura 10 – Diagrama representando as hierarquias na inteligência artificial.	65
Figura 11 – Gráfico apresentando os benefícios da implementação de <i>Transfer Learning</i>	67
Figura 12 – Diagrama representando o aprendizado profundo.	70
Figura 13 – Representação da camada CNN em ação.	74
Figura 14 – Representação exemplificada de uma convolução 2D.	76
Figura 15 – Fluxograma PRISMA dos artigos investigados para o estado da arte.	79
Figura 16 – Representação da interface neural HDsEMG com 64 canais.	80
Figura 17 – Gráfico HDsEMG com canais dos movimentos de Desvio Radial e Ulnar do punho.	81
Figura 18 – Gráfico HDsEMG com canais do movimento de circundação do punho.	82
Figura 19 – Sinais sEMG dos 4 grupos de movimentos selecionados.	83
Figura 20 – Ilustração das aquisições dos sinais cinemáticos e da interface neural HDsEMG.	85
Figura 21 – Fotografia dos movimentos realizados pelo antebraço.	87
Figura 22 – Representação de uma rede neural artificial.	90
Figura 23 – Diagrama com comandos e códigos para treinamento das CNN pelo <i>Deep Learning Toolbox</i> do MATLAB.	90
Figura 24 – Comparação por diagramas para <i>Machine Learning</i> e <i>Deep Learning</i>	91
Figura 25 – Diagramas com camadas de treinamento de uma DP.	92

Figura 26 – Exemplo dos processos de treinamento de uma CNN.	93
Figura 27 – Linhas de comando do ambiente MATLAB para iniciar as classes DAG- Network e SeriesNetwork.	93
Figura 28 – Arquitetura em blocos das camadas das CNN GoogleNet e VGG19. . .	96
Figura 29 – Exemplo de uma matriz de confusão binária.	97
Figura 30 – Diagrama representado as estruturas dos testes e métricas.	99
Figura 31 – Gráfico com 64 sinais HDsEMG processados e reorganizados.	101
Figura 32 – Plotagem do algoritmo de extração de <i>labels</i>	102
Figura 33 – Gráfico de extração de <i>labels</i> dos sinais HDsEMG.	102
Figura 34 – Gráfico de sobreposição da extração de <i>labels</i> do HDsEMG	103
Figura 35 – Gráfico de extração de características do HDsEMG	103
Figura 36 – Gráfico com classificadores PCA reorganizado por <i>labels</i>	104
Figura 37 – Exemplos dos escalogramas criados para as classes dos treinamentos. .	105
Figura 38 – Matriz de Confusão do modelo CNN GoogLeNet para as classes de movimentos MFP e MHP.	105
Figura 39 – Matriz de Confusão do modelo CNN GoogLeNet para as classes de movimentos MDR e MDU.	106
Figura 40 – Matriz de Confusão do modelo CNN GoogLeNet para as classes de movimentos MCH e MCA.	107
Figura 41 – Matriz de Confusão do modelo CNN GoogLeNet para as classes de movimentos MFI e MFM.	108
Figura 42 – Matriz de Confusão do modelo CNN VGG19 para as classes de movi- mentos MFP e MHP.	109
Figura 43 – Matriz de Confusão do modelo CNN VGG19 para as classes de movi- mentos MDR e MDU.	110
Figura 44 – Matriz de Confusão do modelo CNN VGG19 para as classes de movi- mentos MCH e MCA.	111
Figura 45 – Matriz de Confusão do modelo CNN VGG19 para as classes de movi- mentos MFI e MFM.	112

LISTA DE TABELAS

Tabela 1 – Músculos dos membros superiores e outras regiões próximas investigados em interfaces HDsEMG entre 2000 e 2020.	34
Tabela 2 – Dados bibliográficos das Interfaces HDsEMG da década de 2000.	35
Tabela 3 – Dados bibliográficos das Interfaces HDsEMG da década de 2010.	36
Tabela 4 – Dados bibliográficos das Interfaces HDsEMG de 2018.	37
Tabela 5 – Dados bibliográficos das Interfaces HDsEMG de 2019.	38
Tabela 6 – Dados bibliográficos das Interfaces HDsEMG de 2020.	38
Tabela 7 – Valores das funções de treinamento do modelo CNN GoogLeNet para as classes de movimentos MFP e MHP.	106
Tabela 8 – Valores das funções de treinamento do modelo CNN GoogLeNet para as classes de movimentos MDR e MHP.	107
Tabela 9 – Valores das funções de treinamento do modelo CNN GoogLeNet para as classes de movimentos MCH e MCA.	108
Tabela 10 – Valores das funções de treinamento do modelo CNN GoogLeNet para as classes de movimentos MFI e MFM.	109
Tabela 11 – Valores das funções de treinamento do modelo CNN VGG19 para as classes de movimentos MFP e MHP.	110
Tabela 12 – Valores das funções de treinamento do modelo CNN VGG19 para as classes de movimentos MDR e MDU.	111
Tabela 13 – Valores das funções de treinamento do modelo CNN VGG19 para as classes de movimentos MCH e MCA.	112
Tabela 14 – Valores das funções de treinamento do modelo CNN VGG19 para as classes de movimentos MFI e MFM.	113
Tabela 15 – Comparação de classificação entre as métricas de validação das CNNs GoogLeNet e VGG19.	114

LISTA DE ABREVIATURAS E SIGLAS

2D	Bidimensional
3D	Tridimensionais
ACC	Accuracy - Acurácia
AI	Artificial Intelligence - Inteligências Artificiais
AVDs	Atividades da Vida Diária
BCI	Brain-Machine Interface - Interface Cérebro-Maquina
BMI	Brain-Computer Interfaces - Interfaces Cérebro-Computador
CKC	Convolution Kernel Compensation
CNN	Convolution Neural Network - Rede Neural Convolucional
CNS	Central Nervous System - Sistema Nervoso Central
CoV	Coefficient of Variation
DBS	Deep Brain Stimulation - Estimulação Profunda do Cérebro
DL	Deep Learning - Aprendizado Profundo
EEG	Eletroencefalografia
EMG	Eletromiografia ou Sinal Eletromiográfico
EMG-PR	Electromyography Pattern Recognition
ESP	Especificidade
FE	Feature Extraction - Extrações de Características
FES	Function Electrical Stimulation - Estimulação Elétrica Neuromuscular Funcional
FPC	First Principal Component - Primeiro Componente Principal
FPCA	Functional Principal Component Analysis

FPGA	Field Programmable Gate Arrays
HDsEMG	High-Density Surface Electromyography - Eletromiografia de Superfície de Alta Densidade
IAP	Propagação de um Potencial de Ação Intracelular
IBGE	Instituto Brasileiro de Geografia e Estatística
LDA	Linear Discriminant Analysis
MACP	Músculo Abdutor Curto do Polegar
MADM	Músculo Abdutor do Dedo Mínimo
MAP	Músculo Abdutor do Polegar
MBRA	Músculo Braquiorradial
MCA	Movimentos de Circundação do Pulso no Sentido Anti-Horário
MCH	Movimentos de Circundação do Pulso no Sentido Horário
MDR	Movimentos de Desvio Radial
MDU	Movimentos de Desvio Ulnar
MED	Músculo Extensor dos Dedos
MFCM	Músculo Flexor Curto do Dedo Mínimo
MFCP	Músculo Flexor Curto do Polegar
MFI	Movimento de Flexão Interfalangeana e Metacarpofalangeana
MFM	Movimentos de Fechamento da Mão
MFP	Movimentos de Flexão do Pulso
MFPD	Músculo Flexor Profundo dos Dedos
MFRC	Músculo Flexor Radial do Carpo
MFSD	Músculo Flexor Superficial dos Dedos

MFUC	Músculo Flexor Ulnar do Carpo
MHP	Movimentos de Hiperextensão do Pulso
MIDO	Músculos Interósseos Dorsais
ML	Machine Learning - Aprendizado de Máquina
MLP	Multilayer Perceptron
MODM	Músculo Oponente do Dedo Mínimo
MOP	Músculo Oponente do Polegar
MPMA	Músculo Peitoral Maior
MPME	Músculo peitoral Menor
MRPs	Mãos Robóticas Protéticas
MT	Músculo Trapézio
MTB	Músculo Tríceps Braquial
NMJ	Sistema Neuromuscular Junção
PCA	Principal Component Analysis - Análise de Componentes Principais
PMRs	Pesquisas em Mãos Robóticas
PNS	Peripheral Nervous System - Sistema Nervoso Periférico
PO	Prestação de Serviços de Próteses e Órteses
PR	Pattern Recognition - Reconhecimento de Padrões
GLR	Razão de Verossimilhança Generalizada
ReLU	Unidade de Ativação Linear Retificada
RMSE	Root Mean Square Error - Desvio da Raiz Quadrática Média
RPO	Repouso
SE	Sensibilidade

SEL	Seletividade
sEMG	Eletromiografia de Superfície
SENIAM	Surface Electromyography for the Non-Invasive Assessment of Muscles - Eletromiografia de Superfície para Avaliação Não-invasiva dos Músculos
SFAPs	Potencial Individual de Ação de Fibra
SIHSUS	Sistema de Informações Hospitalares do Sistema Único de Saúde
SNMF	Sparse Non-negative Matrix Factorization
SVM	Support Vector Machine

SUMÁRIO

1	INTRODUÇÃO	18
1.1	A MÃO	21
1.1.1	<i>Membro Superior: Braço, Antebraço e Mão</i>	21
1.1.2	<i>Amputação do Membro Superior</i>	24
1.2	ESTADO DA ARTE	28
1.2.1	<i>Mãos Robóticas Protéticas</i>	28
1.2.2	<i>Acionamento e Arquitetura das Mãos Robóticas Protéticas</i>	32
1.3	OBJETIVOS	39
1.4	CONTRIBUIÇÕES DA TESE	39
1.5	ESTRUTURA DA TESE	41
2	FUNDAMENTAÇÃO TEÓRICA	42
2.1	INTERFACES CÉREBRO-MÁQUINA	42
2.2	NEUROPRÓTESES DE MEMBRO SUPERIOR	44
2.3	ELETROMIOGRAFIA DE SUPERFÍCIE (sEMG)	48
2.3.1	<i>Estrutura e Modelagem Matemática sEMG</i>	49
2.3.2	<i>Eletromiografia de Superfície de Alta Densidade (HDsEMG)</i>	55
2.4	PRÉ-PROCESSAMENTO HDsEMG	56
2.4.1	<i>Recursos para o Pré-processamento HDsEMG</i>	56
2.4.2	<i>Rotulação e Janelamento HDsEMG</i>	59
2.4.3	<i>Análise dos Componentes Principais</i>	62
2.4.4	<i>Transformadas de Wavelets Contínuas e Discretas</i>	63
2.5	INTELIGÊNCIA ARTIFICIAL	65
2.5.1	<i>Transferência de Aprendizado</i>	66
2.5.2	<i>Deep Learning</i>	67
2.5.3	<i>Redes Neurais Convolucionais CNN</i>	70
2.5.4	<i>Normalização</i>	76
3	MATERIAIS E MÉTODOS	78
3.1	LEVANTAMENTO BIBLIOGRÁFICO	78
3.2	EQUIPAMENTOS E MATERIAIS	80

3.2.1	<i>Interface Neural HDsEMG</i>	80
3.2.2	<i>Software MATLAB</i>	83
3.2.3	<i>Hardware para aquisição de sinais cinemáticos</i>	84
3.3	PROTOCOLO EXPERIMENTAL	85
3.3.1	<i>Setup de Aquisição HDsEMG</i>	85
3.3.2	<i>Construção do Banco de Dados</i>	86
3.3.3	<i>Dados dos Voluntários</i>	87
3.4	MODELOS CNN IMPLEMENTADOS	88
3.4.1	<i>Arquitetura do Modelo CNN GoogLeNet</i>	94
3.4.2	<i>Arquitetura do Modelo CNN VGG19</i>	95
3.5	PERFORMANCE: TESTES E MÉTRICAS	96
4	RESULTADOS E DISCUSSÕES	100
4.1	HDsEMG Processado	100
4.2	RESULTADOS REDES NEURAIAS CONVOLUCIONAIS	105
4.2.1	<i>Matrizes de confusão e métricas para CNN GoogLeNet</i>	105
4.2.2	<i>Matrizes de confusão e métricas para CNN VGG19</i>	109
5	CONCLUSÕES	116
	REFERÊNCIAS	119

1 INTRODUÇÃO

As mãos representam funções motoras e sensoriais para o cérebro, onde as preensões, movimentos para manipulação e reconhecimento de objetos e ambientes estão entre as tarefas com coordenações mais complexas das funções cerebrais (CASTIELLO, 2005; MENDEZ *et al.*, 2021). Um dos principais métodos para reconhecimento e modificação do ambiente ao nosso redor é manipulando-o com as mãos, seja quando estamos construindo um objeto, modificando a natureza, segurando um copo de água, ou nos alimentando. A perda da capacidade de movimentação das mãos ou de partes do membro superior interfere diretamente no desenvolvimento das atividades da vida diária (AVDs) e podem resultar em transtornos psicológicos por reduzirem significativamente a independência. Os cinco principais fatores para a perda de um membro são: as doenças neurológicas, como por exemplo a doença de *parkinson* e a esclerose múltipla, ou por eventos traumáticos, como uma lesão cerebral, uma lesão na medula espinhal ou a amputação da mão (BENSMAIA; TYLER; MICERA, 2020; SHOKUR *et al.*, 2021).

Para Meyer (2003) a qualidade de vida de um indivíduo que perde o membro superior está comprometida. Para auxiliar estes indivíduos a restaurar algumas das funções perdidas após uma amputação, pode-se adquirir uma prótese de membro superior. Segundo Belter, Segil e SM (2013) as próteses estão se tornando cada vez mais hábeis e eficazes, desta forma os designs das Interfaces Cérebro-Máquina confiáveis e intuitivas se tornaram um desafio e tem apresentado resultados significativos para dispositivos e arquiteturas neuroprotéticas (BORTON *et al.*, 2013). A aceitabilidade e usabilidade de uma mão protética depende principalmente da sua gama de funcionalidade, sendo elas robustez mecânica e controlabilidade (FRANZKE *et al.*, 2019), mas se as próteses forem capaz de transmitir feedback sensorial artificial similar e eficaz próximo ao natural, resultaria no aumento da aceitação pelo usuário (GRACZYK *et al.*, 2016; SAAL; BENSMAIA, 2015).

Apesar da gama de estudos realizados para compreender os mecanismos de funcionamento das mãos, ainda existem muitos domínios para serem explorados e esta é uma das razões pelas quais as mãos artificiais continuam sendo um dos maiores desafios da robótica moderna (PIAZZA *et al.*, 2019). Segundo D’Anna (2018), as próteses atuais para membros superiores ainda demandam desenvolvimento e pesquisas científicas para o aperfeiçoamento em suas atuações e funcionalidades.

Nas últimas décadas foram constatados inúmeros casos de abandono de próteses de membro superior e estima-se que aproximadamente 45% dos amputados que adquiriram suas próteses a rejeitaram em algum momento do processo de adaptação ou nas utilizações durante as AVDs, considerando aspectos como por exemplo, funcionalidade limitada, peso excessivo, controle não intuitivo, constantes acionamentos não desejados e falta de confiabilidade. E sem este suporte a perda de um membro superior transforma negativamente a qualidade de vida de um indivíduo, onde as AVDs, simples ou complexas, se tornam um obstáculo em suas execuções (AHMADIZADEH *et al.*, 2017; VALLE *et al.*, 2020).

Inicialmente, é importante compreender como a ausência dos membros superiores podem afetar o nosso desenvolvimento, considerando que a mão exerce uma função relevante e integral na vida profissional e social de um indivíduo saudável. As mãos nos fornecem uma gama de condições sociais, como a independência a autonomia. Os membros superiores são ainda compreendidos como princípio de produtividade, expressão, afeto e comunicação (MEYER, 2003).

Aproximadamente 57,7 milhões de pessoas vivem com a amputação de membros no mundo (MCDONALD *et al.*, 2020). Logo, há uma necessidade global de serviços protéticos, porém, tanto para ações de desenvolvimento quanto para profissionais da área da protética os índices demográficos apresentam severas defasagem neste setor. A literatura aponta que as causas de amputações de membros variam dependendo com região geográfica. Por exemplo, doenças arteriais periféricas e a diabetes são comumente identificadas como as principais causas de amputação de membros em países desenvolvidos (AHMAD *et al.*, 2014; BEHRENDT *et al.*, 2018). No entanto, em países emergentes os registros com maior incidência são os de amputação causados por traumas mecânicos decorrentes de acidentes (MOINI *et al.*, 2009; SHAW *et al.*, 2018). Traumas e amputações de membros nestes países são apontados e identificados como uma epidemia amplamente negligenciada, sendo necessário reestruturação nas assistências, nas prevenções e nos tratamentos (AGARWAL-HARDING *et al.*, 2016; KRUG; SHARMA; LOZANO, 2000).

O último censo demográfico realizado no Brasil pelo Instituto Brasileiro de Geografia e Estatística (IBGE) já completou uma década. Os dados epidemiológicos daquela época apresentavam uma incidência de 23,9% da população brasileira, ou seja, aproximadamente 45,6 milhões de pessoas apresentavam algum dos tipo de deficiência investigada, tais como deficiências visuais, auditivas, motoras e mentais ou intelectuais, considerando que 7% apresentam alguma deficiência motora (OLIVEIRA *et al.*, 2012).

No dia 31 de Julho de 2018 o IBGE lançou o documento intitulado Nota Técnica 01/2018, apresentando uma nova interpretação dos dados epidemiológicos do Brasil, sendo uma releitura sobre a identificação de pessoas com deficiência. Desta forma, foram incluídos como pessoas com deficiência apenas os indivíduos que possuem alguma deficiência severa, sendo agora consideradas 12 milhões de pessoas comparado ao censo demográfico brasileiro que está em vigor até a data desta publicação. No entanto, para Peixoto *et al.* (2017), Carvalho, Sena e Neto (2020) existe uma prevalência no número de amputações no país, mesmo considerando a nota atual citada. Os dados epidemiológicos das regiões Sul, Sudeste e Nordeste apresentam crescimento exponencial em amputações nos últimos anos.

No ano de 2018 foram registradas 59 mil amputações no Brasil, considerando ainda a estimativa de um milhão de amputações no mundo a cada ano. Souza, Santos e Albuquerque (2019) apontam que os dados clínico-epidemiológicos ainda carecem de estrutura e organização. No Brasil o sistema que disponibiliza estes dados é o Sistema de Informações Hospitalares do Sistema Único de Saúde (SIHSUS).

Os atuais módulos neurotecnológicos (NTs) apresentam uma gama de possibilidades para satisfazer as problemáticas citadas e o desenvolvimento de neuropróteses para membro superior vem crescendo exponencialmente na última década. A confecção de neuropróteses exige uma estrutura multidisciplinar combinando as áreas e as experiências em ciência da computação, engenharias elétrica, mecânica e biomédica, também processos com micro e nanotecnologia celular e molecular e sistemas em neurociência (SHOKUR *et al.*, 2021).

Neste capítulo será apresentado o membro superior e suas estruturas, os conceitos básicos sobre a amputação do membro superior e os aspectos fundamentais para compreensão do desenvolvimento de sistemas neuropróticos, disponíveis na Seção 1.1. O estado da arte sobre próteses comerciais e de pesquisas com sistemas robóticos de mão juntamente com o estado da arte sobre a evolução e o desenvolvimento de interfaces neurais que utilizam o conceito *High Density Surface Electromyography (HDsEMG)* (MERLETTI; CERONE, 2020) que traduzido para a língua portuguesa se refere à Eletromiografia de Superfície de Alta Densidade.

1.1 A MÃO

1.1.1 Membro Superior: Braço, Antebraço e Mão

Segundo a tradução da obra *De Anima: On the Soul* por Shiffman *et al.* (2012) Aristóteles cita "a mão é a ferramenta das ferramentas". A mão é capaz de executar uma gama de ações em razão de sua principal função, a preensão. Da perspectiva fisiológica, a mão representa a extremidade executora das possibilidades de posicionamento realizado pelo membro superior garantindo sua voluntária e determinada ação. A mão é um órgão destinado a obtenção de informações e a execução de tarefas, tendo em sua anatomia essas duas funções especificamente expressas como essenciais em nosso relacionamento com o meio social, sendo responsável pela importância e singularidade da extremidade superior do corpo humano. A mão possui uma grande amplitude de espaço para sua movimentação, podendo alcançar qualquer parte do corpo por conta da mobilidade articular gerada pelo membro superior que inclui as estruturas do ombro, do cotovelo e do punho, cada um com seus diferentes planos de movimentação (TUBIANA, 1981; TUBIANA; THOMINE; MACKIN, 1996).

Na literatura estão presentes diversos relatos sobre o significado social das mãos, o desempenho e a importância da mão como um órgão de ação e percepção são reconhecidos em todos os segmentos das ciências sociais. O homem utiliza suas mãos como instrumentos, referências a simbolismos e como armas em sua própria defesa. Diversas suposições folclóricas e religiosas apresentam mitos e superstições sobre as mãos que foram sendo construídas ao longo da história humana. As mãos podem substituir a forma de reconhecer o ambiente para um deficiente visual. Muitas vezes se tornou símbolo de saudação e formas de comunicação, abordando extremos como a súplica ou a condenação e também exerceu o desenvolvimento do potencial criativo em todas as sociedades conhecidas (ALPENFELS, 1955).

A mão não se destina apenas em um órgão motor de execução, mas também um completo sistema sensorial com uma ampla estrutura com receptores funcionais, cuja atuação está diretamente relacionado para o feedback de suas ações. O córtex cerebral em conjunto com essas estruturas, fornecem aos indivíduos compreensão e conhecimento do meio como dimensionamento, distância, espessura, peso, temperatura e texturas, isso resulta no controle e na interpretação das informações adquiridas com as mãos (KAPANDJI, 2000).

Portanto, a mão aliada ao cérebro constitui um sistema funcional intrínseco, garantindo que cada componente interaja logicamente entre si. E com isso podemos considerar a capacidade do ser humano em manipular e modificar a natureza de acordo com seus intuitos, lhe proporcionando habilidades superiores em relação aos demais seres vivos do planeta.

A aplicação mecânica da mão evoluiu conforme as necessidades do homem, pois essa estrutura tem como base um sistema ósseo bem articulado. A estrutura óssea e as articulações da mão são responsáveis pelas formações mecânicas dos movimentos, resultando pinças, prensões e garras. A estrutura dos sistemas nervosos, musculares e os tendões são responsáveis pelo controle, acionamento e permanência dos movimentos reproduzidos.

Na Figura 1 é apresentada uma ilustração das mãos em formato de concha, para exemplificar uma das diversas prensões que elas podem realizar, essa prensão conta com o auxílio da gravidade gerando assim um eficiente recipiente para segurar e manipular grãos e líquidos, tipo de ação fundamental para nossa evolução e desenvolvimento.

Figura 1 – Ilustração das mãos realizando uma prensão, movimento para manipular grãos e líquidos.



Fonte: Desenho vetorizado pelo próprio autor.

A sua importância da mão vem sendo relatada em diversas pesquisas arqueológicas, apontando até mesmo o sucesso da evolução humana a partir do polegar opositor e as primeiras ferramentas primitivas. Nos anos de 1960, um conjunto de ossos da mão

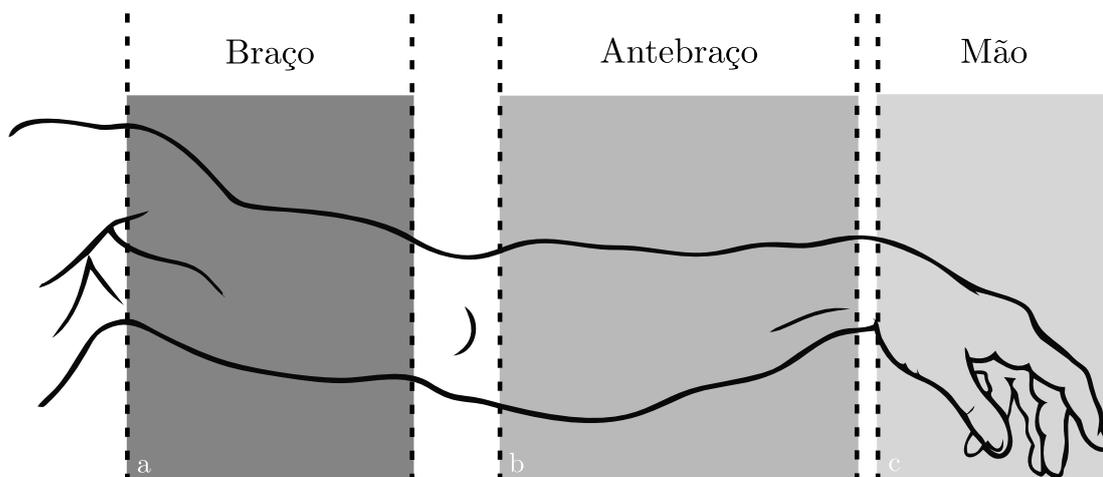
foram encontrados em *Olduvai Gorge*, na Tanzânia, no mesmo local foram encontradas ferramentas de pedra primitivas, datados com cerca de um milhão e setecentos e cinquenta mil anos. Partes de um crânio e mandíbula foram associados com o restante dos ossos e da sua morfologia, concluiu-se que este espécime, o *OH7*, foi um dos primeiros membros do nosso gênero humano, o *Homo* (LEAKEY; TOBIAS; NAPIER, 1964).

Embora encontrado parte da mão, os ossos apresentam ter um padrão simiesco sugerindo a capacidade de uma consistente flexão dos dedos e há evidências de que o polegar era bastante similar à do polegar humano moderno, na sua amplitude de movimento e em sua capacidade de flexionar fortemente a sua extremidade (NAPIER, 1962). A espécie foi nomeada *Homo Habilis*, o homem prático e seus descobridores afirmam que essa era mão era capaz de fazer as ferramentas encontradas, encontrando um fundamento sobre o papel das ferramentas na evolução humana, especificamente sobre relatos morfológicos de fabricação de ferramentas criadas, que prevalecem até os dias atuais.

Segundo Fransson-Hall e Kilbom (1993), a mão está localizada parte mais distal do membro superior, assim pode operar com mais liberdade e alcançar diferentes pontos em qualquer posicionamento, aceitando determinados limites em qualquer orientação, resultando toda mobilidade das articulações do membro superior, incluindo o ombro que é a articulação que possui maior mobilidade no corpo humano. Os membros possuem uma nomenclatura específica para se referir a sua posição no corpo, sendo elas as regiões distais e proximais. A região distal é compreendida pela parte localizada na extremidade do membro e a região proximal é compreendida pela parte localizada mais próxima ao torso, ou seja, no tronco.

O membro superior é composto por três partes fundamentais para garantir as preensões desejadas, sendo eles o braço, o antebraço e a mão. O braço, considerado primeira parte do membro superior, está disposto entre a espádua até o cotovelo, a espádua consiente em uma das estruturas ósseas que compõem o ombro. O antebraço, parte do membro superior que está disposto entre o cotovelo e o punho. E para concluir a mão parte extrema do membro superior, está conectada ao punho. Na língua portuguesa é usual utilizar o termo *braço* para denominar todo o membro superior. A Figura 2 apresenta uma ilustração para identificar as regiões e divisões das estruturas que formam o membro superior o braço (*a*), o antebraço (*b*) e a mão (*c*) respectivamente.

Figura 2 – Ilustração do membro superior para identificar suas divisões em braço, antebraço e mão.



Fonte: Desenho do membro superior adaptado de Buonarroti (1475)

1.1.2 Amputação do Membro Superior

A amputação é uma ocorrência traumática com ação incapacitante, gerando danos para realização das AVDs e também das atividades profissionais (D'ANNA, 2018). A amputação consiste na remoção de um membro, um apêndice ou saliência do corpo, na ocorrência de lesões graves de nervos, artérias, músculos, ossos e pele (MEYER, 2003). A amputação é o último recurso a ser considerado, buscando sempre a possibilidade de reabilitação e também de restabelecimentos das funções do membro (PEIXOTO *et al.*, 2017).

A restauração de funções motoras perdidas em indivíduos amputados tem sido um grande desafio para grupos de pesquisa em neuroengenharia que realizam estudos para o desenvolvimento de próteses de membros superiores, como a mão biônica (D'ANNA, 2018).

Avanços tecnológicos promissores no design e na fabricação de dispositivos protéticos de membros superiores estão apresentando resultados tanto nos sistemas ativos funcionais como nas próteses cosméticas soluções para indivíduos com amputações de membros superior (ESQUENAZI, 2004). Há uma ampla complexidade e diversidade de funções a serem realizadas pelas mãos incluindo sua relevância no processo de comunicação e auto-apresentação (PILLET; DIDIERJEAN-PILLET, 2001). Considerando essa complexidade o desenvolvimento de sistemas protéticos de membros superiores apresentam desafios consideráveis para reabilitação e restauração protética (DESMOND, 2007).

Fatores Comportamentais e Psicológicos

Segundo Meyer (2003), a amputação das mãos resultam em transtornos físicos e também em traumas psicológicos, pois conflitam diretamente com os sentimentos de culpa e punição em relação a então perda de autonomia e potência. A amputação de um membro, como a mão pode pôr fim na vida profissional de um indivíduo afetando diretamente a atividade laboral que ele desenvolvia e suas habilidades motoras finas ficam comprometidas. Para Desmond (2007) a amputação de um membro superior também apresenta uma infinidade de desafios físicos e psicossociais, incluindo alterações na imagem corporal e no estilo de vida.

Os profissionais de saúde que atendem pacientes com amputação devem estar conscientes destes fatores e com isso, devem fornecer todo suporte psicoterapêutico e socioassistencial em seu protocolo (MEYER, 2003). No entanto, podemos considerar também uma eficácia se o cirurgião responsável pela amputação adotar uma estratégia e uma perspectiva biopsicossocial, modelo da medicina que estuda a causa e a evolução das doenças considerando os aspectos biológicos, psicológicos e sociais (SIMÕES; ATHIAS; BOTELHO, 2018).

Principais Fatores e Estatísticas Demográficas

São inúmeros os fatores que resultam em amputações de membro superior, variam de acidentes traumáticos como acidente de trabalho, acidente de trânsito e confrontos bélicos por exemplo, malformação congênita e doenças como a diabetes, certos tipo de câncer, infecções e outros. Os tipos e as variações das ocorrências das amputações variam em todo o mundo, sempre registrando os maiores índices de casos em países emergentes. As amputações por lesões traumáticas estão em maior ocorrência entre os jovens, diferentemente das amputações geradas por doenças nos indivíduos mais idosos. Esse índice aumenta a problemática envolvendo a redução das capacidades motoras do indivíduo e seu desempenho em sociedade, considerando que os amputados mais jovens conseqüentemente realização mudanças consideráveis em suas vidas profissionais, afetando seu desenvolvimento por toda vida.(D'ANNA, 2018).

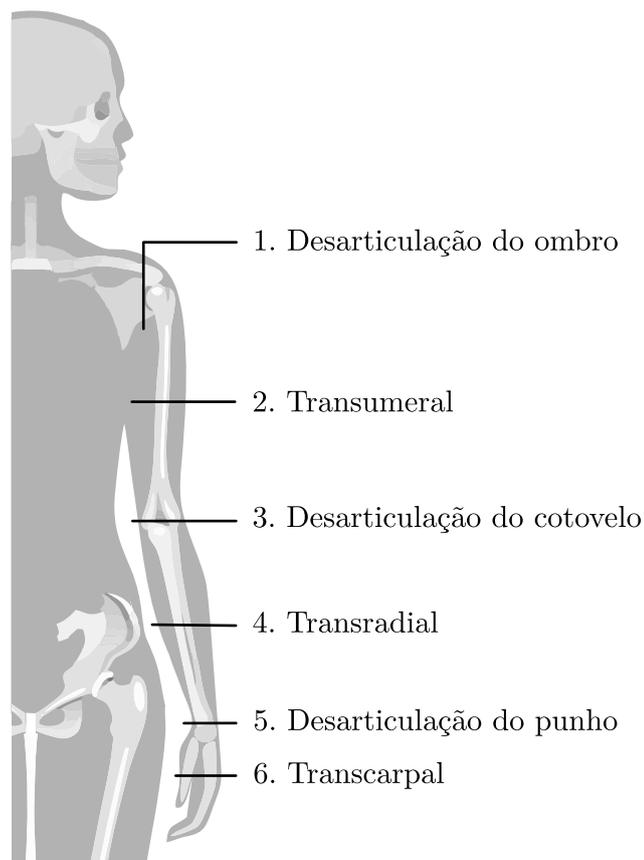
Segundo McDonald *et al.* (2020) as principais causas traumáticas com amputações de membro foram relacionadas a quedas maiores que a própria altura totalizando 36,2% dos

casos registrados, acidentes rodoviários totalizando 15,7% dos casos registrados, acidentes com transportes totalizando 11,2% dos casos registrados e amputações causadas por forças e ações mecânicas totalizando 10,4% de todos os casos registrados. A maior recorrência de amputações traumáticas foram registrados no Leste Asiático e no Sul da Ásia, em sequência a Europa Ocidental, Norte da África, o Oriente Médio, a América do Norte e a Europa Oriental.

McDonald *et al.* (2020) estimaram que existem aproximadamente 57,7 milhões pessoas amputadas por causas traumáticas no mundo referente ao ano de 2017, sendo estimado aproximadamente 35 milhões de pessoas com amputação nos membros inferiores e 23 milhões pessoas com amputação nos membros superiores. Em concordância com essas estatísticas, a investigação de D'Anna (2018) aponta para um crescimento exponencial nos próximos 30 anos, no número de amputações dos membros superiores na América do Norte região de referência global, onde os principais fatores deste avanço serão ocasionados pela doença crônica metabólica *Diabetes Mellitus*, conhecida popularmente como diabetes. É importante considerar que a diabetes é a principal causa de amputações de membros nos países desenvolvidos e a amputação de membros inferiores com esta causa apresenta maior ocorrência, um quarto comparado ao número de amputados dos membros superiores.

As amputações são classificadas por regiões (partes) dos membros onde ocorreram o trauma, essas classificações são definidas por níveis determinados nas regiões amputadas denominada, Níveis de Amputação. Os níveis de amputação dos membros superiores são definidos em seis estruturas, iniciando pela parte proximal do membro superior, tem-se; a amputação por desarticulação do ombro, a amputação transumeral, a amputação por desarticulação do cotovelo, a amputação transradial, a amputação por desarticulação do punho e a amputação transcarpal (PIERRIE; GASTON; LOEFFLER, 2018; MADURI; AKHONDI, 2019; RESNIK *et al.*, 2020). A Figura 3 representa em ordem numérica a sequência dos níveis de amputação do membro superior.

Figura 3 – Representação dos níveis de amputação dos membros superiores.



Fonte: Elaboração do próprio autor.

Com o intuito de aperfeiçoar o processo de reabilitação protética em pessoas com amputação dos membros, a Organização Mundial da Saúde (OMS) publicou recentemente padrões para prestação de serviços de próteses e órteses (PO). Essas diretrizes destacam quatro aspectos fundamentais para prestação nestes serviços juntamente com as políticas dos sistemas de saúde, como fornecimento de produtos, provisão e atenção pessoal. Além disso, a escassez de protesistas treinados foram identificados como uma barreira fundamental para o cumprimento no desenvolvimento e na reabilitação protética globalmente.

Dados da Sociedade Internacional de Próteses e Órteses (SIPO) apresentado pela OMS, sugere que todos os países carecem de profissionais especializados em próteses e órteses. Estudos apontam que apontam a escassez de profissionais protesistas e ortesistas nos países desenvolvidos e afirmam ainda que essa situação é ainda pior quando comparado para os países emergentes (MCDONALD *et al.*, 2020). De acordo com esses estudos a estimativa é que a prevalência das amputações geram consequências globais, sendo uma delas a necessidade de operação de aproximadamente 75.850 protesistas e ortesistas ao redor do mundo para atuarem no tratamento de pessoas amputadas.

Considerando a prevalência dos casos em países emergentes, os fatores responsáveis pelo quadro atual e os aspectos estruturais, nortearam o segmento a ser investigado, Segundo D'Anna (2018) e os demais dados demográficos apresentados, aproximadamente 60% de todas as amputações de membros superiores em países emergentes ocorrem com traumas abaixo do cotovelo, considerando essas evidências a amputação transradial foi definida como tema de investigação para esta tese.

1.2 ESTADO DA ARTE

1.2.1 Mãos Robóticas Protéticas

Restaurar as funções motoras dos membros superiores é uma busca milenar, pois, historicamente os seres humanos utilizavam artefatos para substituir a ausência de seus membros. Os avanços tecnológicos permitem o desenvolvimento de membros superiores artificiais eficazes e os métodos de construção de dispositivos biônicos de mão considerados atualmente como sistemas desafiadores para robótica, promovendo um crescimento exponencial em pesquisas nesta área. Implementar uma prótese biônica consiste em agrupar diversas áreas do conhecimento para tornar viável a interação entre o usuário e a prótese, mesclar esses diversos conceitos de forma a garantir eficiência e conforto não é uma tarefa trivial (PIAZZA *et al.*, 2019; MENDEZ *et al.*, 2021).

Portanto, décadas de pesquisas e produtos em mãos robóticas protéticas (MRPs) estão disponíveis na literatura e a variedade de sistemas desenvolvidos comprovam como é desafiador integrar uma prótese funcional ao corpo humano. No entanto, compatibilizar soluções mecatrônicas avançadas, sensores com novas técnicas de interfaces robustas podem resultar em acionamentos mais próximos do natural, ou seja, eficiência na controlabilidade (MENDEZ *et al.*, 2021).

Nas últimas duas décadas não foram medidos esforços para que esses sistemas sejam usualmente fáceis de controlar, confortáveis e com acionamento intuitivo. Observa-se pela literatura, que as arquiteturas destes dispositivos devem ter um comprometimento entre destreza mecânica, robustez e usabilidade (BICCHI, 2000). Recentemente, novas perspectivas foram propostas por pesquisadores ao redor do mundo com os sistemas que implementam feedbacks neurais e essas propostas que podem aumentar consideravelmente a aceitabilidade e o desempenho desta nova geração de MRPs (MENDEZ *et al.*, 2021).

As mãos robóticas são divididas em dois seguimentos: as MRPs e as pesquisas em mãos robóticas (PMRs). As MRPs são sistemas já implementados e validados comercialmente para habilitação e reabilitação de amputados. Destacando-se a empresa alemã *Ottobock*, a empresa islandesa *Össur* pioneiras no desenvolvimento de próteses para membros inferiores e superiores. Suas aplicações com mãos biônicas mioelétricas para amputações transradiais dominam o mercado protético desde de 2010 (MENDEZ *et al.*, 2021). Já as PMRs apresentam as maiores contribuições para mãos robóticas intuitivas e inúmeras investigações com feedback sensorial e manipuladores robóticos traçam uma significativa perspectiva das MRPs em médio e longo prazo. A Figura 4 apresenta um diagrama contendo os tipos de mãos robóticas e cada tecnologia presentes nas MRPs e PMRs (MENDEZ *et al.*, 2021).

Figura 4 – Diagrama com os tipos de Mãos Robóticas: Mãos Robóticas Protéticas e Pesquisas de Mãos Robóticas.



Fonte: Elaboração do próprio autor.

As mãos robóticas podem ser classificadas em diversos conceitos como (a) Robótica Assistiva: sistemas voltados para o desempenho do indivíduo com o meio pela robótica, essa perspectiva está relacionada às tecnologias assistivas. Um destes sistemas são as mãos DLR (BUTTERFASS *et al.*, 2001). (b) Próteses: sistemas comerciais disponíveis para usuários como a mão biônica *BeBionic*, mão biônica *i-Limb* ou a mão biônica *Michelangelo* (MEDYNSKI;

RATTRAY, 2011; CONNOLLY, 2008; LUCHETTI *et al.*, 2015). (c) Robótica Social: sistemas robóticos implementados para interação social com antropomorfismo facilitando a aceitação na comunicação e na interação da sociedade e seguindo este conceito também são aplicadas próteses de baixo custo como a comunidade e-NABLE (PARRY-HILL *et al.*, 2017), Mão Biónica Galileo (FAJARDO *et al.*, 2020), OpenBionics (LIAROKAPIS *et al.*, 2014) e a Mão Augusto (XAVIER, 2016).

(d) Manipuladores Robóticos Supervisionados: permite a integração entre braços mecânicos e outros dispositivos e são capazes de realizar ações no ambiente com supervisão e controle externo ao usuário (PIAZZA *et al.*, 2019). (e) Teleoperação e Teleinteração: sistemas com acionamento e interações remotas, onde diversas aplicações podem ser observadas, tais como interações para exploração espacial como a mão *Robonaut* ou um sistema androide com capacidade de realizar movimentos de preensão como o robô *ASIMO* (AMBROSE *et al.*, 2000; HIROSE; OGAWA, 2007).

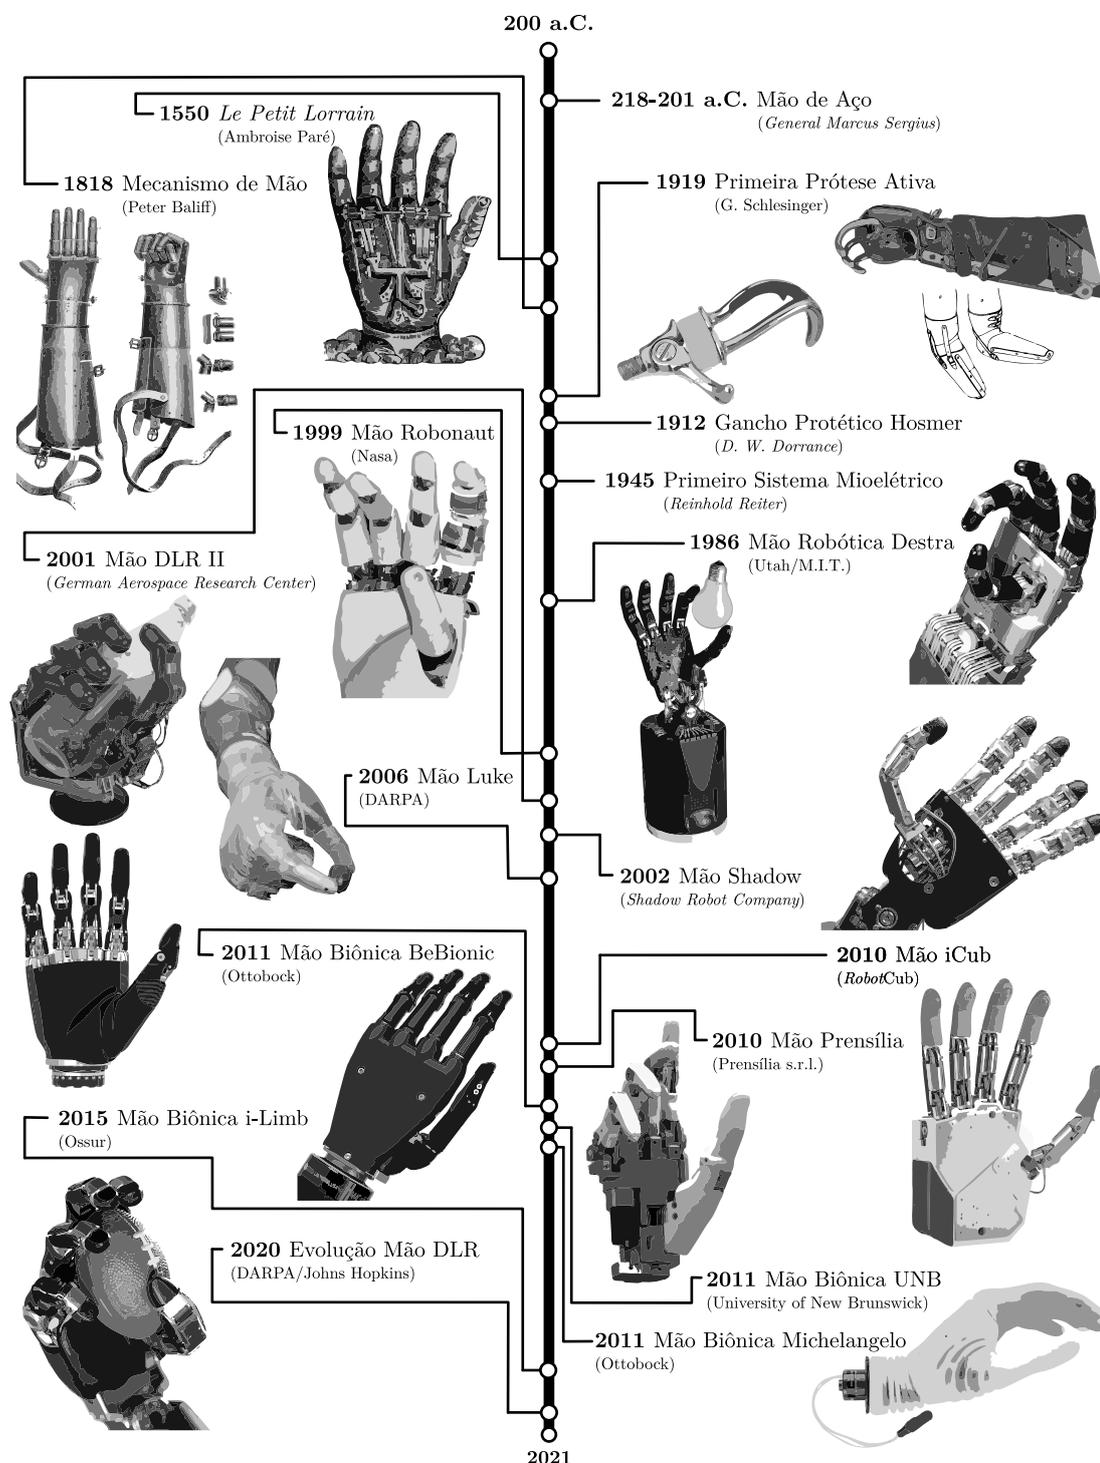
Os mecanismos que compõem as mãos robóticas apresentam diferentes estruturas ao longo do seu desenvolvimento e podemos observar a utilização de diversas técnicas para o desenvolvimento de articulações, tais como, articulações rígidas onde as conexões utilizam elementos mecânicos fixos como pinos e eixos mecânicos, as articulações flexíveis onde as conexões utilizam elementos mecânicos flexíveis com molas, as articulações deslocáveis onde as conexões utilizam elementos elásticos podendo resistir a desarticulações severas e as articulações maleáveis onde as conexões utilizam elementos macios (PIAZZA *et al.*, 2019).

Nos atuadores mecânicos responsáveis pelos movimentos dos sistemas robóticos, pode-se identificar diferentes princípios, como por exemplo, atuador rígido, atuador com controle ativo de impedância e admitância, atuador elástico em série, atuador de rigidez variável explícita, atuador de rigidez variável agonista-antagonista e atuador de impedância variável. Para transmissões mecânicas as ações que permitem direcionar os atuadores para as articulações disponíveis são transmissores de acionamento total estruturas as articulações são conectadas diretamente no atuador, transmissores de acoplamento estruturas onde existem mais articulações do que graus de liberdade (DOFs) e transmissores de subatuação estrutura que geram movimentos passivos em relação aos DOFs permitindo adaptação da mão em relação ao objeto agarrado (PIAZZA *et al.*, 2019).

A Figura 5 representa uma linha do tempo de 200 a.C até os dias atuais, apresentando as principais contribuições em mecanismos de mãos robóticas. Foram selecionadas

as MRPs e PMRs que mais contribuíram para o avanço das mãos robóticas até os dias atuais.

Figura 5 – Representação das principais mãos robóticas ao longo da história.



Fonte: Elaboração do próprio autor.

1.2.2 Acionamento e Arquitetura das Mãos Robóticas Protéticas

A literatura atual está repleta de trabalhos e pesquisas científicas nas áreas citadas anteriormente, entretanto, ainda existem pontos fundamentais no desenvolvimento de tecnologias para neuropróteses (VALLE *et al.*, 2020; D'ANNA, 2018). O acionamento dos sistemas robóticos protéticos por HDsEMG se tornou o objetivo de diversos grupos de pesquisa no mundo e considerando isso, esta tese é parte integrante na busca por esses avanços tecnológicos.

Para responder inúmeras perguntas sobre a arquitetura, estrutura e aplicabilidade das interfaces neurais por EMG, foi estruturada uma busca na literatura considerando as últimas duas décadas, procurando por implementações que unem as interfaces HDsEMG com as IAs, garantindo assim uma contribuição na arquitetura da interface neural proposta nesta tese, aplicando os modelos mais atuais para o treinamento e aprendizado de máquinas, capazes de melhorar a qualidade de vida dos usuários de próteses de membros superiores.

A metodologia para o levantamento bibliográfico apresentado nesta sessão será apresentada no capítulo que versa sobre materiais e métodos. Para implementação de uma nova interface neural capaz coletar, armazenar e processar um banco de dados de biosinais de alta densidade é necessário que o hardware de aquisição e o software para processamento sejam projetados para garantir um desempenho eficiente. Sendo assim, o estado da arte é o caminho para parametrização e mapeamento deste novo sistema.

No primeiro momento, foram coletados dados de artigos científicos que abrangem a implementação de dispositivos HDsEMG e o pós processamento dos sinais por IA. Os seguintes parâmetros foram coletados: arquitetura e dimensionalidade do hardware de cada interface HDsEMG, quais músculos foram mapeados e analisados nas aquisições, quais as tarefas e atividades foram aplicadas no protocolo de aquisição, qual a região do membro superior foi investigada, quais as modelagens matemáticas e técnicas de IA foram aplicadas para processamento dos sinais e quais os principais resultados dos artigos investigados.

No desenvolvimento desta interface foi definida a amputação transradial, que se define por um trauma no antebraço, ou seja, entre o cotovelo e o punho do indivíduo, os níveis de amputação foram apresentados na Seção 1.1.2.

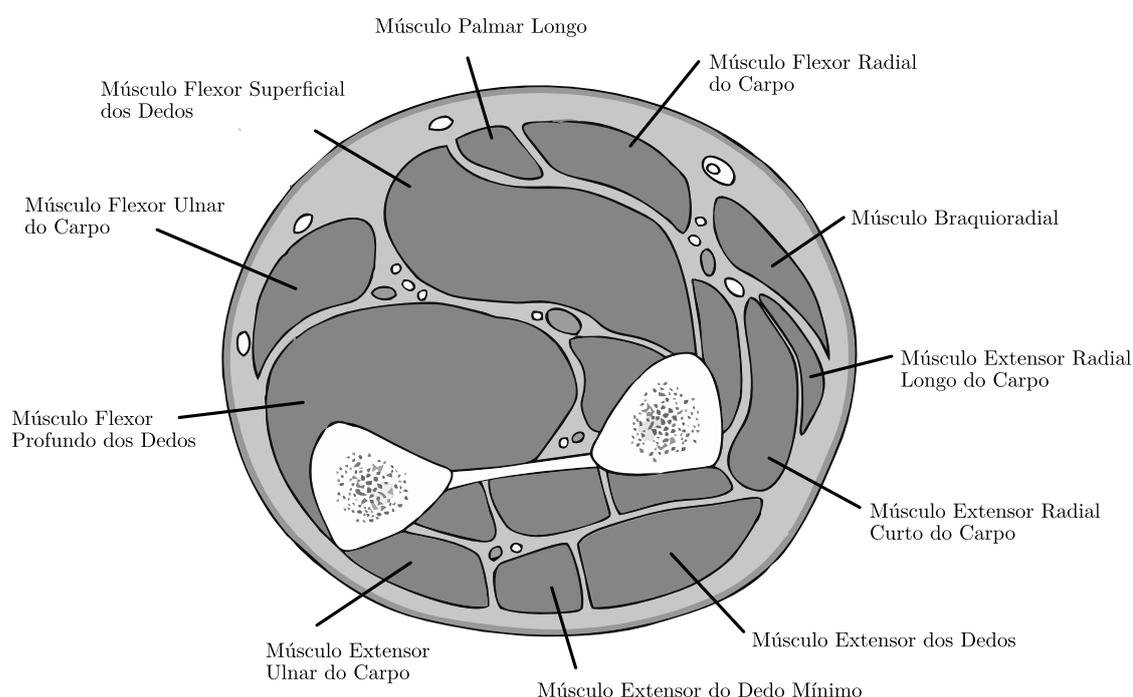
Desta forma, um dos principais fatores na seleção dos artigos investigados se concentram em dispositivos HDsEMG implementados no antebraço. Foram considerados também

artigos com aplicações de EMG em outras regiões do corpo, que contém informações que se conectam a esta investigação.

Para compreensão de quais músculos do antebraço estão na região da superfície para aquisição dos sinais eletromiográficos de superfície (sEMG), foram consultados diversos autores em fisiologia e trabalhos relacionados.

A Figura 6 apresenta uma ilustração com os músculos superficiais, pela perspectiva de um corte transversal no antebraço.

Figura 6 – Ilustração dos músculos superficiais do antebraço.



Fonte: Adaptado de Gray e Standring (2008).

Na Tabela 1 são apresentados os músculos e os conjuntos musculares do antebraço e regiões próximas que apareceram com maior frequência na literatura ao longo dos últimos 20 anos em trabalhos com HDsEMG.

Os músculos superficiais permitem a aquisição de sinais em toda extensão do corpo e o sEMG, quando amplificado, fornece uma gama de informações sobre seu funcionamento, tais como ativação motora neural, carga e descarga das contrações musculares sendo armazenados para processamento posterior, *offline* ou aplicado em tempo real com protocolos *online*.

A Tabela 2 apresenta os primeiros estudos com HDsEMG. Os parâmetros investigados foram: a região dos membros superiores utilizados considerando as regiões proximais ou distais que foram aplicados o HDsEMG; o número de eletrodos (canais) do hardware

Tabela 1 – Músculos dos membros superiores e outras regiões próximas investigados em interfaces HDsEMG entre 2000 e 2020.

Músculos
Músculo Abdutor Curto do Polegar (MACP)
Músculo Abdutor do Polegar (MAP)
Músculo Abdutor do Dedo Mínimo (MADM)
Músculo Braquiorradial (MBRA)
Músculo Extensor dos Dedos (MED)
Músculo Flexor Curto do Dedo Mínimo (MFCM)
Músculo Flexor Curto do Polegar (MFCP)
Músculo Flexor Profundo dos Dedos (MFPD)
Músculo Flexor Radial do Carpo (MFRC)
Músculo Flexor Superficial dos Dedos (MFSD)
Músculo Flexor Ulnar do Carpo (MFUC)
Músculos Interósseos Dorsais (MIDO)
Músculo Oponente do Dedo Mínimo (MODM)
Músculo Oponente do Polegar (MOP)
Músculo Peitoral Maior (MPMA)
Músculo Peitoral Menor (MPME)
Músculo Trapézio (MT)
Músculo Tríceps Braquial (MTB)

Fonte: Elaboração do próprio autor.

HDsEMG e as informações da matriz de distribuição dos elétrodos; e por fim os músculos recrutados nas tarefas definidas nos protocolos de cada artigo.

Staudenmann *et al.* (2005) implementaram uma HDsEMG e realizaram ensaios classificatórias em modo *offline*, eles também destacam o avanço de 30% na classificação de seus resultados, comparados com a utilização com sEMG.

Os mesmos autores, um ano após esta publicação, publicaram uma implementação integrando HDsEMG com a implementação do método *Principal Component Analysis* (PCA), que traduzido para a língua portuguesa se refere à análise dos componentes principais, concluindo o estudo com uma melhora de 40% em comparação a implemen-

Tabela 2 – Dados bibliográficos das Interfaces HDsEMG da década de 2000.

Autores	Membro	Nº de Canais (<i>matriz</i>)	Músculos
(STAUDENMANN <i>et al.</i> , 2005)	Braço	260 (<i>26x20</i>)	TB
(STAUDENMANN <i>et al.</i> , 2006)	Braço	130 (<i>10x13</i>)	TB
(MERLETTI; HOLOBAR; FARINA, 2008)	Ombro	61 (<i>13x5</i>)	MT,ADM
(HARGROVE; ENGLEHART; HUDGINS, 2008)	Antebraço	128 (<i>16x8</i>)	BRA,ED,FPD,FUC,FRC
(HUANG <i>et al.</i> , 2009)	Braço	128 (<i>16x8</i>)	PMA,PME,BB

Fonte: Elaboração do próprio autor.

tação anterior (STAUDENMANN *et al.*, 2006). Os dados também apresentam uma redução significativa na quantidade de elétrodos nas interfaces propostas.

No ano de 2008 Merletti, Holobar e Farina (2008) utilizaram o método *Convolution Kernel Compensation*(CKC) para processamento de multicanais de sinais eletromiográficos apresentado por Holobar e Zazula (2007). O grupo de pesquisa Merletti, Holobar e Farina (2008) ainda define o entendimento desse método por uma nova interface de aquisição de sEMG, descrevendo não ser apenas possível analisar EMG como uma única interferência nas variáveis adquiridas globalmente no momento das aquisições dos sinais no músculo.

Mas os autores consideram que a partir deste momento que o EMG pode ser decomposto analisando regiões específicas dos potenciais de ação nas unidades motoras, relacionando também a capacidade da interface fornecer informações sobre os impulsos neurais para os músculos e propriedades das membranas das fibras musculares, o então HDsEMG.

Nas pesquisas de Hargrove, Englehart e Hudgins (2008) e Huang *et al.* (2009) são utilizados os métodos de *Linear Discriminant Analysis* (LDA) pertencente a área de estatística e outros campos, onde a análise de função discriminante consiste em encontrar uma combinação linear de recursos que caracterizam duas ou mais classes de objetos ou eventos.

A Tabela 3 apresenta os trabalhos desenvolvidos na segunda década dos anos 2000. Nestes trabalhos, os pesquisadores utilizaram HDsEMG para investigar se indivíduos com amputações transradiais poderiam produzir padrões de classificação com sinais eletromiográficos processados com *pattern recognition* (PR), para o acionamento de próteses mioelétricas (DALEY; ENGLEHART; KURUGANTI, 2010).

Daley *et al.* (2012) verificou que as métricas na classificação do sistema implementado não sofreu alterações significativas quando os números de elétrodos foram reduzidos. Os

autores demonstraram também que a associação com PR se tornam uma ferramenta robusta para avaliação e classificação de sinais neurais adquiridos com HDsEMG.

Boschmann *et al.* (2017) demonstram que a interação entre HDsEMG com *field programmable gate arrays* (FPGA) juntamente com *Feature Extraction* (FE) podem resultar em uma acurácia do sistema em até 97% na classificação e reconhecimento de classes para o acionamento de próteses mioelétricas.

Tabela 3 – Dados bibliográficos das Interfaces HDsEMG da década de 2010.

Autores	Membro	Nº de Canais (<i>matriz</i>)	Músculos
(DALEY; ENGLEHART; KURUGANTI, 2010)	Antebraço	64 (8×8)	BRA,ED,FPD,FUC,FRC
(ROJAS-MARTÍNEZ; MAÑANAS; ALONSO, 2012)	Braço	350 (10×35)	BRA,BB,TB
(ZHANG; ZHOU, 2012)	Braço	89 (10×8)	IDO,FCP,AP,OP,FCM,ADM,ODM
(DALEY <i>et al.</i> , 2012)	Antebraço	64 (16×4)	BRA,ED,FPD,FUC,FRC
(GENG <i>et al.</i> , 2014)	Antebraço	56 (8×6)	IDO,FCP,AP,OP,FCM,ADM,ODM
(AMMA <i>et al.</i> , 2015)	Antebraço	192 (24×8)	ED,FPD,FPL,FSD
(PAN <i>et al.</i> , 2015)	Antebraço	192 (24×8)	BRA,ED,FPD,FUC,FRC
(STANGO; NEGRO; FARINA, 2014)	Antebraço	192 (24×8)	BRA,ED,FPD,FUC,FRC
(BOSCHMANN <i>et al.</i> , 2017)	Antebraço	192 (24×8)	BRA,ED,FPD,FUC,FRC

Fonte: Elaboração do próprio autor.

As investigações de Zhang e Zhou (2012), Stango, Negro e Farina (2014) e Boschmann *et al.* (2017) descrevem a utilização do método *Support vector machine* (SVM) em suas análises com HDsEMG. Uma máquina de vetores de suporte consiste em um conjunto de métodos de aprendizado supervisionado para processar e reconhecer padrões na aquisição de dados e é utilizado na classificação e análise de regressão.

A partir do ano de 2018, ano de definição do tema e desenvolvimento da proposta desta tese, as investigações foram realizadas ano após ano, sendo eles, os anos de 2018, 2019 e 2020 buscando assim um levantamento recente e atualizado sobre a utilização das interfaces neurais HDsEMG. A Tabela 4 apresenta estes resultados:

Chen *et al.* (2019) apresentam uma abordagem utilizando HDsEMG e o método de *first principal component* (FPC), parte integrante das análises com PCAs. Foram correlacionados os dados de HDsEMG com dados cinemáticos adquiridos por câmeras de vídeo que armazenam em tempo real os movimentos pretendidos nas tarefas propostas.

Após isso, os dados cinemáticos são processados juntos com o HDsEMG e essa informação fornece o tempo exato das descarga dos sinais neurais das Unidades Motoras (UM) investigadas. E esses tempos são conhecidos como classes ou *labels* e são responsáveis

Tabela 4 – Dados bibliográficos das Interfaces HDsEMG de 2018.

Autores	Membro	Nº de Canais (<i>matriz</i>)	Músculos
(HE <i>et al.</i> , 2018)	Antebraço	64 (8×8)	BRA,ED,FPD,FUC,FRC
(MOIN <i>et al.</i> , 2018)	Antebraço	64 (8×8)	BRA,ED,FPD,FUC,FRC
(SHIN; HU, 2018)	Braço	128 (16×8)	BB
(DAI; CAO; HU, 2018)	Antebraço	160 (20×8)	ED
(CHEN <i>et al.</i> , 2019)	Antebraço	64 (8×8)	BRA,ED,FPD,FUC,FRC
(JARQUE-BOU <i>et al.</i> , 2018)	Antebraço	8 (4×2)	BRA,ED,FPD,FUC,FRC
(LIN <i>et al.</i> , 2018)	Antebraço	16 (4×4)	BRA,ED,FPD,FUC,FRC
(SAMUEL <i>et al.</i> , 2018)	Braço	32 (8×4)	BRA,ED,FPD,FUC,FRC,TB,BB
(KAPELNER <i>et al.</i> , 2017)	Antebraço	64 (8×8)	FCR

Fonte: Elaboração do próprio autor.

pelos processos de classificação e etiquetagem dos movimentos a serem classificados pelo sistema.

Samuel *et al.* (2018) constatou que muitos pesquisadores tem trabalhado com interfaces HDsEMG para identificação de movimentos e o acionamento de dispositivos protéticos. Afirmam também que a interação do HDsEMG com PR e FE proporcionam aos usuários de próteses um alto nível de destreza e intuitividade. A Tabela 5 registrou as principais investigações envolvendo HDsEMG e AI em interfaces desenvolvidas especificamente para o antebraço.

Diversos métodos para análises estatísticas são utilizados na classificação de HDsEMG, esses métodos foram identificados nos artigos investigados, entre eles podemos destacar o *Sparse non-negative matrix factorization* (SNMF), implementado pelo grupo de pesquisa Lin *et al.* (2018) onde a fatoração de matriz não negativa consiste em um grupo de algoritmos para análise multivariada onde a matriz é fatorada garantindo que suas respectivas matrizes não possuam elemento negativo, o *Electromyography pattern recognition* (EMG-PR), implementado por Samuel *et al.* (2018) onde o método de reconhecimento de padrões por eletromiografia consiste na condição fisiológica onde o indivíduo de forma intuitiva pode gerar contrações musculares repetidas e coordenadas gerando padrões para distintos acionamentos, utilizando o conceito de PCAs tem-se o *Functional Principal Component Analysis* (FPCA) implementado por Jarque-Bou *et al.* (2018) e *Coefficient of Variation* (CoV) investigado por Dai, Cao e Hu (2018) o método de variação de coeficiente

consiste na medida estatística da dispersão relativa de pontos de dados em uma série de dados em torno da média.

Tabela 5 – Dados bibliográficos das Interfaces HDsEMG de 2019.

Autores	Membro	Nº de Canais (<i>matriz</i>)	Músculos
(MOIN <i>et al.</i> , 2019)	Antebraço	64 (16×4)	BRA,ED,FPD,FUC,FRC
(BARSOTTI <i>et al.</i> , 2018)	Antebraço	192 (24×8)	BRA,ED,FPD,FUC,FRC
(NOCE <i>et al.</i> , 2019)	Antebraço	8 (4×2)	BRA,ED,FPD,FUC,FRC
(HA; WITHANACHCHI; YIHUN, 2019)	Antebraço	4 (2×2)	FRC,FUC,BRA

Fonte: Elaboração do próprio autor.

Moin *et al.* (2019), Ha, Withanachchi e Yihun (2019) desenvolveram análises para classificação de movimentos da mão, tais como, preensões e movimentos individuais dos dedos. Ambos utilizaram modelos matemáticos de aprendizado como *machine learning* (ML), que traduzido para a língua portuguesa, se refere à aprendizado de máquinas para classificação de cada movimento investigado. A Tabela 6 apresenta os trabalhos mais recentes encontrados na literatura para compreender a arquitetura dos hardwares das interfaces neurais HDsEMG.

Tabela 6 – Dados bibliográficos das Interfaces HDsEMG de 2020.

Autores	Membro	Nº de Canais (<i>matriz</i>)	Músculos
(CLARKE <i>et al.</i> , 2020)	Antebraço	192 (24×8)	BRA,ED,FPD,FUC,FRC
(ISLAM <i>et al.</i> , 2020)	Antebraço	128 (16×8)	BRA,ED,FPD,FUC,FRC
(URH <i>et al.</i> , 2020)	-	-	BB
(CHEN <i>et al.</i> , 2020)	Antebraço	128 (16×8)	-
(BAHADOR <i>et al.</i> , 2020)	Antebraço	128 (16×8)	-
(VECCHIO <i>et al.</i> , 2020)	-	-	-
(WANG <i>et al.</i> , 2020)	Antebraço	48 (8×6)	-
(STACHACZYK; ATASHZAR; FARINA, 2020)	Antebraço	64 (8×8)	FSD
(ISLAM; MASSICOTTE; ZHU, 2020)	Antebraço	128 (16×8)	-

Fonte: Elaboração do próprio autor.

Nos últimos dois anos tivemos um crescimento exponencial com aplicações em aprendizado profundo ou *deep learning* (DL) como apresetnado na tabela anterior. Nas investigações desenvolvidos em 2020, os pesquisadores apresentaram uma alta demanda de utilização da rede neural convolucional ou *convolution neural network* (CNN), as

CNNs também conhecidas como *ConvNet* é uma classe das DPs, utilizada para analisar e processar imagens, sua arquitetura e modelos são descritos e apresentados no Capítulo 2.

Os autores Islam *et al.* (2020), Chen *et al.* (2020), Bahador *et al.* (2020), Stachaczyk, Atashzar e Farina (2020), Islam, Massicotte e Zhu (2020) utilizaram os métodos CNNs para o apredizado de suas classes. As classes CNN de *Deep Learning* serão abordados e implementados no desenvolvimento desta tese para treinamento e processamento dos dados obtidos com a interface neural implementada.

1.3 OBJETIVOS

Considerando a necessidade de desenvolvimento de uma interface neural com características comparáveis com implementações mundiais e considerando também que é possível utilizar técnicas de *Deep Learning* para explorar as correlações de Neuroprotéses Transradiais–HDsEMG através do banco de dados coletados pelo TNELab, são dois os objetivos desta tese:

- Implementar modelos de *Deep Learning* utilizando uma interface neural utilizando HDsEMG.
- Comparar e avaliar o uso de novas técnicas para classificações com movimentos musculares no acionamento de neuropróteses transradiais.

1.4 CONTRIBUIÇÕES DA TESE

Esta tese é resultante da integração entre a Universidade Estadual de São Paulo (UNESP), câmpus de Ilha Solteira localizada em São Paulo, Brasil e a *École Polytechnique Fédérale de Lausanne* (EPFL) no Campus Biotech (CB) localizado Genebra, Suíça, sendo que ambas universidades tiveram papeis fundamentais na formação pessoal e acadêmica do autor. As interações principais ocorreram pela conexão dos dois grupos de pesquisa o Laboratório de Instrumentação e Engenharia Biomédica (LIEB) do Departamento de Engenharia Elétrica (DEE) da UNESP e o *Translational Neural Engineering Lab* (TNE) do Centro de Neuropróteses (CNP) da EPFL.

As principais contribuições deste trabalho estão relacionadas ao desenvolvimento, implementação e otimização de algoritmos, bancos de dados de uma interface neural

para acionamento de sistemas neuroprotéticos. Os resultados obtidos com esta pesquisa permitirão a realização de futuras investigações e aprimoramentos relacionados ao tema como (i) à implementação de tecnologia para acionamento de neuropróteses na reabilitação das funções dos membros superiores; (ii) maior performance na seleção e na realização de movimentos da mão; (iii) confiabilidade e segurança no desempenho do sistema para o usuário; e (iv) controle intuitivo com acionamento não invasivo. A seguir, serão apresentadas as contribuições obtidas com esta pesquisa.

A interface neural implementada para aquisição de HDsEMG permite a aquisição de biosinais no antebraço: essa disposição se torna relevante para o mapeamento de todas as regiões possíveis no momento de armazenar as informações das contrações musculares voluntárias dos usuários, fundamental para o acionamento de neuropróteses transradiais. Além disso, permite processar e armazenar informações e estabelecer diferentes relações entre modelos de IA. A relevância desta interface é que pode ser implementada em ambientes não laboratoriais, permitindo sua implementação em próteses e neuropróteses disponíveis para usuários.

Implementação de algoritmos para extração de recursos dos HDsEMG. Para garantir melhor desempenho no treinamento das IAs. Pois, uma vez implementado neste sistema, pode ser adaptado e reestruturado para interação com diferentes dispositivos.

Implementação de um algoritmo para classificar os parâmetros de EMG. O sistema permite selecionar e etiquetar os mais diversos tipos de contrações realizados pelo antebraço, característica essencial devido à necessidade de obtenção de classificar contrações musculares para o acionamento do sistema.

Obtenção de um banco de dados com às características EMG do antebraço durante movimentos do membro superior: O banco de dados obtido permite estruturar os treinamentos necessários para criação de um modelo viável e eficiente no reconhecimento de padrões durante o acionamento do sistema pelo usuário. Esse banco de dados é base fundamental para o processo de aprendizado dos modelos propostos.

Obtenção de padrões dos movimentos relacionados às características EMG dos membros superiores: As contrações musculares obtidas após processadas fornecem padrões facilitando a compreensão e o treinamento de novos modelos de IA para o acionamento de sistemas protéticos. Isso permite o desenvolvimento de tecnologias para populações com amputação do membro superior. Adicionalmente, estabelecer o impacto do da seleção de movimentos finos e precisos que permita projetar sistemas protéticos mais eficientes.

1.5 ESTRUTURA DA TESE

Neste capítulo foram apresentados conceitos que contribuem para desenvolvimento das pesquisas, focando principalmente no entendimento e estrutura dos membros superiores, o estado da arte e visando entender a relação Neuropróteses Transradiais–HDsEMG os fatores que os conectam com Inteligência Artificial.

Para atingir os objetivos propostos, foi necessário realizar um estudo aprofundado dos diferentes sistemas e ferramentas tanto de *hardware* como de *software*.

No Capítulo 2 apresenta a fundamentação teórica desvelando conceitos fundamentais para o desenvolvimento desta tese. São abordados os métodos e evolução das interfaces cérebro–máquina, neuropróteses de membros superiores, arquiteturas das interfaces HD–sEMG e inteligências artificiais.

No Capítulo 3 o desenvolvimento e a implementação de uma nova interface neural é descrita, desde a seleção dos circuitos até a metodologia de avaliação para parametrização do sistema. Também é apresentado ferramentas de *software* e, mais especificamente, algumas técnicas de *Deep Learning*. São apresentados ainda alguns classificadores binários supervisionados e metodologias aplicadas para sua implementação.

No Capítulo 4 são apresentados os resultados e as discussões das pesquisas realizadas.

No Capítulo 5 são apresentadas as principais conclusões das pesquisas e sugestões para realização de trabalhos futuros.

No Capítulo 6 são apresentadas as referências bibliográficas.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados os conceitos fundamentais para desenvolvimento do sistema proposto, as interações com interfaces cérebro-máquina e suas contribuições nos dias atuais que norteiam os caminhos a serem seguidos durante as implementações propostas. Em seguida será apresentado o conceito de neuropróteses e suas estruturas. Para definir a compreensão em interfaces neurais é apresentado os conceitos de sEMG e HDsEMG e para que essa integração resulte em acionamentos robustos e eficazes são apresentados os conceitos em Inteligência Artificial que baseiam a utilização de *deep learning* com classes de redes neurais convolucionais para classificação de movimentos robóticos intuitivos.

2.1 INTERFACES CÉREBRO-MÁQUINA

Segundo Lebedev e Nicolelis (2017), se considerarmos três décadas atrás não imaginávamos os desenvolvimentos de interfaces neurais capazes de conectar um cérebro a um dispositivo artificial. Como por exemplo, sistemas embarcados, microprocessadores, dispositivos biônicos e sistemas robóticos. Esta nova linha de pesquisa em neurociência nasce em um ambiente multidisciplinar e os conceitos para a implementação dessas interfaces começaram a surgir no início do século XX (BERGER, 1935; JOSEPH, 1985; ANDERSEN; ESSICK; SIEGEL, 1985). A primeira demonstração científica desta interface ocorreu em 1999, onde um conjunto de neurônios eram capazes de controlar diretamente um manipulador robótico. Após a publicação deste trabalho, inúmeras pesquisas científicas em BCI foram desenvolvidas e isso é resultante da capacidade tecnológica para restauração das funções motoras em pacientes com essa deficiência (CHAPIN *et al.*, 1999). O atual interesse em sistemas com BMIs é resultado do potencial que essa tecnologia pode fornecer, principalmente nas áreas de reabilitação e protética (LEBEDEV; NICOLELIS, 2006; MOXON *et al.*, 2000; WOLPAW *et al.*, 2000).

Recentemente tecnologias em neurociência transformaram ideias que antes eram vistas como ficção científica em realidade, a busca pelo mapeamento das funções cerebrais e a compreensão de nossos pensamentos impulsionou um gama de pesquisas para o desenvolvimento de conceitos e técnicas aplicadas na implementação de interfaces capazes de conectar o cérebro em dispositivos artificiais. As aplicações são inúmeras e o mercado

já possui produtos que realizam essa integração, sendo possível encontrar dispositivos para conexão cerebral com computadores, módulos de controle neural para smartphones e tablets, *gedgets* como capacetes e óculos para aquisição e processamento de sinais eletroencefalográficos. Em pesquisas científicas podemos observar a rápida expansão e evolução de dispositivos robóticos acionados e controlados por interfaces cerebrais, tanto para sistemas invasivos ou sistemas não invasivos como cadeiras de rodas motorizadas, braços robóticos e exoesqueletos (LEBEDEV; NICOLELIS, 2006).

As interfaces neurais são sistemas de aplicação a níveis cerebrais, sendo assim as interfaces cérebro-maquina ou *brain machine interface* (BCI) ou ainda *brain-Machine interfaces* (BMIs) com interações de implantes nos nervos periféricos, tendo como objetivo solucionar e amenizar deficiências que afetam as AVDs. Pesquisas recentes em neuroengenharia mostram implantes neurais cada vez mais complexos, capazes de traduzir e compreender milhares de interações e funções neurais simultaneamente.

As BMIs tem o objeto como objetivo principal desenvolver caminhos alternativos para integração do indivíduo com deficiência em suas AVDs. Em diversos casos os pacientes por traumas apresentaram deficiências motoras severas e, dessa forma, tecnologias como essas são fundamentais. As BMIs consistem no reconhecimento e na aquisição de dados cerebrais específicos como estímulos externos ou modulação das atividades neurais, essas atividades podem estar associadas a diversas intenções do indivíduo. Quando os sinais adquiridos são processados o resultado vai depender da arquitetura desenvolvida para realizar uma ação (TONIN; MILLÁN, 2021).

As interfaces em geral são arquitetadas de acordo com a sua necessidade e realização com as atuais técnicas de aprendizado de máquinas e essas arquiteturas utilizam diversos conceitos. Os conceitos fundamentais para implementação de uma BMI são: aquisições de biosinais e pré-processamento, extração de características, algoritmos de classificação de características, classificadores lineares e classificadores não lineares e classificadores mistos. Deve-se considerar que cada dispositivo implementado possui sua própria arquitetura e elas podem variar. Considera-se também que as BMIs possuem controle temporal que podem ser classificadas como síncronas ou assíncronas (SHANECHI, 2016).

Nas BMIs síncronas a operação funciona de acordo com estímulos externos como visuais, auditivos ou táteis para aquisição de um padrão cerebral, esse padrão será a linguagem para acionamento dos dispositivos durante uma janela temporal. Nas BMIs com operações assíncronas, o indivíduo envia comandos cerebrais para acionar seus dispositivos

sem a necessidade de uma interação temporal e estímulos externos. Nas BMIs existem relações de aprendizado onde as abordagens utilizadas são a de auto-condicionamento do operador, onde o indivíduo recebe um feedback dos sinais adquiridos e aprende ou se condiciona a controlá-los de forma a produzir um padrão a ser interpretado pelas BMIs (SHANECHI, 2016).

2.2 NEUROPRÓTESES DE MEMBRO SUPERIOR

Os homens possuem capacidade de identificar e explorar o ambiente e objetos que os cercam, dotados de estruturas sensoriais complexas que garantem segurança e eficácia em suas ações, que variam de acordo com as informações que recebem ou reproduzem. Essas estruturas sensoriais são conhecidas como os órgãos dos sentidos, sendo eles visão, audição, paladar, olfato e tato. Este amplo sistema sensorial presente no corpo humano, nos permite traduzir qualquer informação do meio físico em frações de segundos (LIEBER; BENSMAIA, 2020; DONOGHUE, 2002).

Considerando isso, as interações manuais estão diretamente relacionadas ao tato, que fornecem uma infinidade de sinais neurais das mãos, transmitindo informações táteis ao cérebro, tais como, formas, tamanhos, textura, temperatura, tempo de contato, referência, localização e pressão (DOWNEY; BROOKS; BENSMAIA, 2020). O tato é um dos cinco sentidos clássicos apresentados por Aristóteles, no entanto, pesquisas o dividem em quatro outros sentidos, sendo eles o sistema somatossensorial, para identificação de texturas, a propriocepção ou cinestesia, para o reconhecimento da localização espacial do corpo no ambiente, a termoccepção como a percepção da temperatura e a nocicepção para a percepção da dor.

Esses sentidos estão associados com a pele, porém, existem diversos órgãos que os possuem, como por exemplo, o labirinto e a medula. Uma vez que não haja visão, por exemplo, com a falta de visibilidade por ausência de luz ou ocultação por algum outro objeto, fora do campo de visão ou quando o indivíduo possui deficiência visual, o tato é necessário para interação e interpretação imediata no momento de uma ação. Entretanto, mesmo com os constantes avanços das tecnologias em neuropróteses, ainda existem limitações no desenvolvimento bidirecional e esse fator interfere diretamente na funcionalidade e usabilidade de uma prótese de membro superior.

Devemos considerar a inclusão de interfaces *peripheral nervous system* (PNS) que traduzido para língua portuguesa se refere ao sistema nervoso periférico (SNP) nos músculos a serem analisados, permitindo assim adquirir e registrar sinais neurais (VALLE *et al.*, 2020). A utilização de estimulação elétrica neuromuscular funcional ou *function electrical stimulation* (FES) e EMG são dois exemplos clássicos dessas aplicações, permitem que a transmissão das informações neurais possa deslocar-se para ambas direções. Essa troca é conhecida como bidirecionalidade (MICERA; NAVARRO, 2009).

Os sistemas artificiais capazes de restaurar parcialmente ou substituir funções motoras neurais ausentes após traumas com amputações, lesões medulares ou disfunções neurais, são chamados de neuropróteses e esses sistemas são uma alternativa terapêutica para pacientes que possuem as mais diversas deficiências neuromotoras. As interfaces neurais bidirecionais estabelecem o controle das neuropróteses e de dispositivos robóticos (RASPOPOVIC *et al.*, 2020).

Um sistema bidirecional implementado permite a transferência de informações entre o sistema nervoso central (CNS) e os sistemas artificiais computadorizados. Essas interfaces neurais variam entre sistemas invasivos e não invasivos e em sua maioria são constituídos de eletrodos, matrizes de microeletrodos e microfios implantados no cérebro (LAUER *et al.*, 2000; NICOLELIS, 2001; DONOGHUE, 2002; PROCHAZKA; MUSHAHWAR; MCCREERY, 2001; ALO; HOLSHEIMER, 2002).

As aquisições de sinais neurais já era uma realidade em 1960 quando pesquisadores realizaram leituras neurais para analisar o comportamento de primatas e seres humanos (DONOGHUE, 2002). A FES também já era utilizada para influenciar funções cerebrais em primatas e no tratamento de disfunções neurológicas em pacientes em 1950. O homúnculo de Penfield, também datado desta época, é considerado um dos trabalhos que deram origem a todos estes seguimentos (SCHOTT, 1993; LENT, 2004). Podemos destacar os implantes de estimulação profunda do cérebro ou *deep brain stimulation* (DBS) como uma notável terapia para aliviar os tremores, a rigidez e bradicinesia da Doença de Parkinson e estes implantes cerebrais são cada vez mais utilizados para tratar outros distúrbios neurológicos (DONOGHUE, 2002).

Diversas neuropróteses são desenvolvidas com interfaces para PNS utilizando eletrodos para estimulação, aquisição e armazenamento de sinais neurais e muitas arquiteturas foram implementadas e comprovadas cientificamente. Dentre estes trabalhos, destacam-se: a FES para substituir artificialmente o controle motor central e estimular diretamente os

nervos periféricos intactos ou músculos de pacientes com lesões do SNC (VALLE; CARPANETO; MICERA, 2020; SELFSLAGH *et al.*, 2019); próteses artificiais destinadas a substituir partes perdidas do corpo (VALLE; CARPANETO; MICERA, 2020); o sEMG para acionamento de próteses artificiais (D'ANNA, 2018), exoesqueletos destinados a aumentar ou restaurar capacidades humanas (PIERELLA *et al.*, 2018); robôs teleoperados para realizar tarefas em ambientes sem condições de intervenção direta de seres humanos (MICERA; NAVARRO, 2009).

Com o avanço da tecnologia grupos de pesquisa ao redor do mundo tem implementado diversas técnicas de estimulação neural para restauração somatossensorial em próteses de membro superior. Essas interfaces são conectadas diretamente às fibras aferentes do PNS, sendo elas responsáveis pela transmissão de informações adquiridas no ambiente para o CNS (VALLE *et al.*, 2020). Com essas ações foram constatadas melhorias significativas ao utilizar a estimulação direta destes nervos para o acionamento das próteses (PETRINI *et al.*, 2019; TAN *et al.*, 2014; VALLE *et al.*, 2018a; VALLE *et al.*, 2018b; PAGE *et al.*, 2018).

A ausência de informações sensoriais das mãos resulta com graves perdas nos controles motores do indivíduo, limitando severamente a manipulação de objetos com destreza. Assim, a Neuroreabilitação tem como principal objetivo a restauração de funções motoras (VALLE *et al.*, 2020). Também é importante ressaltar que o acionamento para cada funcionalidade exercida pelas neuropróteses ocorrem pelo processamento de EMG, parte integral do sistema bidirecional (VALLE *et al.*, 2020; D'ANNA, 2018).

O termo interface inclui todos os elementos de um sistema entre os processadores da máquina e o tecido humano, o eletrodo, os sensores e os fios conectam o interior do corpo com os processadores externos e a aquisição de dados com circuitos e o controle. Componentes fundamentais para uma interface SNP são os eletrodo de aquisição de atividades bioelétricas e os eletrodos (interfaces) que aplicam corrente, a FES e o objetivo da interface é traduzir os sinais bioelétricos em sinais digitais.

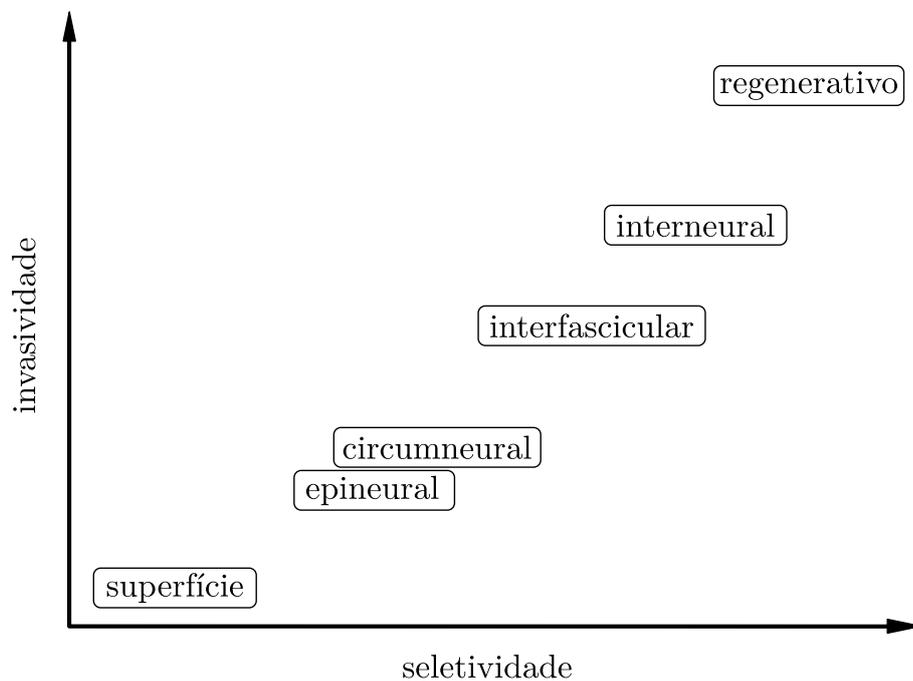
Na perspectiva da engenharia, a interface neural é um transdutor bidirecional que estabelece um contato neuro-técnico entre um dispositivo e uma estrutura fisiológica neural. O objetivo deste transdutor é armazenar sinais bioelétricos de receptores naturais do corpo e estimular artificialmente nervos e músculos. Da perspectiva biológica, essa interface é um corpo estranho. Ambas as perspectivas devem ser conectadas para considerar os requisitos e os aspectos complexos sobre a biocompatibilidade (HEIDUSCHKA; THANOS, 1998; GHAFOOR; KIM; HONG, 2017).

Os implantes crônicos e eletricamente ativos em neuropróteses têm que atender as altas demandas de bioestabilidade e biofuncionalidade, como dimensionalidade, material e interface para garantir que o transdutor temporalmente estável mantenha as propriedades das interfaces eletrodo–eletrólito resultando em uma longa durabilidade dos implantes.

Para interface elétrica seletiva o objetivo é estar em contato com as fibras nervosas o mais seletivamente possível, exigindo dispositivos e tecnologia de fabricação em escalas micrométricas. No entanto, o uso de muitos eletrodos nem sempre fornece a seletividade desejada (GHAFOOR; KIM; HONG, 2017).

Na Figura 7, é apresentado um gráfico com os diferentes tipos de eletrodos aplicados à interface PNS classificados sobre invasividade e seletividade. Isto representa uma classificação geral, apesar de que a seletividade realmente depende do tipo de nervo sob considerações anatômicas e fisiológicas para cada aplicação.

Figura 7 – Gráfico com os tipos de eletrodos para interfaces PNS.

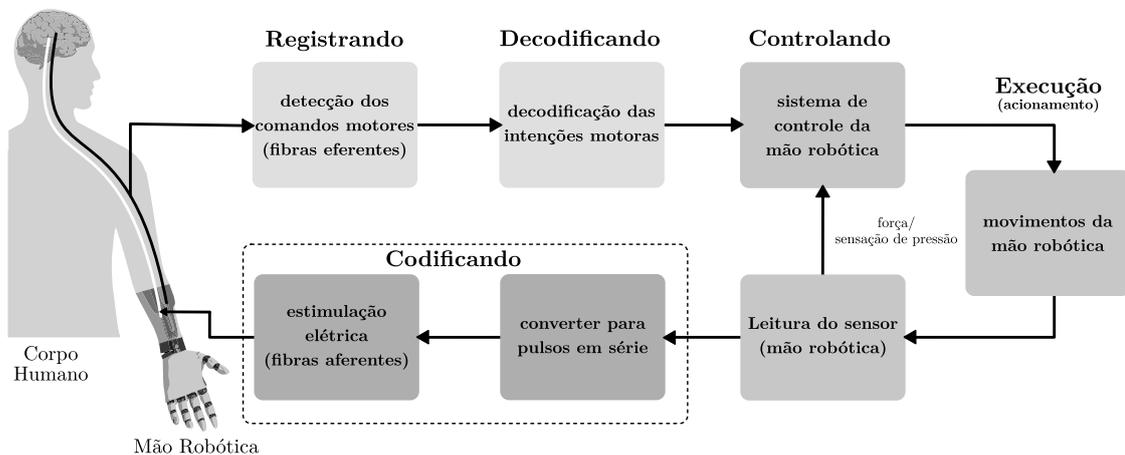


Fonte: Adaptado de Navarro *et al.* (2005).

Ghafoor, Kim e Hong (2017) descreveram a estrutura aplicada ao SNP responsáveis pela transmissão de comandos motores e feedback sensorial ao cérebro. Segundo os autores, existem três diferentes metodologias para evocar feedback sensorial, sendo elas: (a) feedback indireto (não invasivo), (b) elicitación direta (invasiva) através do nervo periférico usando vários tipos de interfaces e (c) um método de estimulação cortical para ativar as informações somatossensoriais no córtex cerebral (GHAFOOR; KIM; HONG, 2017).

Uma interface bidirecional de mãos robóticas ideal e com malha fechada apresentam os seguintes componentes, Figura 8: (i) eletrodos de interface PNS para aquisição de dados por sinais de fibras eferentes; (ii) decodificação das intenções motoras do usuário; (iii) aplicação de comandos motores para o sistema biônico; (iv) transmissão dos sinais ao controlador para estabilizar e definir velocidades e forças do sistema; (v) sensores acoplados na mão e na estrutura biônica para capturar as informações externas; e (vi) um subsistema sensorial para codificar o feedback neural em FES por sinais de fibras aferentes, que evoca a sensação produzida pelo contato com um objeto e auxilia na contração muscular quando necessário.

Figura 8 – Gráfico com conceito de controle bidirecional para mãos robóticas.



Fonte: Adaptado de Ghafoor, Kim e Hong (2017).

2.3 ELETROMIOGRAFIA DE SUPERFÍCIE (SEMG)

Para Merletti e Cerone (2020), os principais sinais biomédicos adquiridos de forma não invasiva são as interfaces com eletrodos de superfície presentes nos sistemas de aquisição em Eletrocardiografia (ECG), responsável pela aquisição dos sinais do coração, eletroencefalografia (EEG) responsável pela aquisição dos sinais do cérebro e o sEMG responsáveis pela aquisição dos sinais dos músculos. O EMG é o diagnóstico aplicado em protocolos clínicos e as aplicações com esses diagnósticos estão presentes nas áreas de monitoramento e avaliações eletrofisiológicas, em fisioterapia, reabilitação, medicina preventiva, ocupacional, esportiva, obstetrícia e robótica (MERLETTI; CERONE, 2020).

A eletromiografia de superfície é bidimensional (2D). Consiste de uma distribuição do potencial elétrico (isto é, voltagem) sobre a superfície da pele e essa distribuição de

potencial é analógica e contínua, podendo gerar em sua aquisição de sinais, imagens ou mapas que evoluem no tempo, podendo ser comparado a um filme (MERLETTI; CERONE, 2020; MERLETTI; MUCELI, 2019). Nas últimas duas décadas o projeto europeu intitulado eletromiografia de superfície para avaliação não invasiva dos músculos ou *surface or electromyography for non-invasive assessment of muscles* (SENIAM) tem sido utilizado como referencial e os protocolos e diretrizes deste projeto são apresentados em diversas pesquisas na literatura (HERMENS; MERLETTI; FRERIKS, 1996).

2.3.1 Estrutura e Modelagem Matemática sEMG

Estrutura da Unidade Motora

Um dos elementos fundamentais para o funcionamento do músculo esquelético são unidades motoras (MUs), que consistem de neurônios motores as fibras musculares que inervam esses neurônios. Nesta Seção são apresentadas os modelos matemáticos das propriedades elétricas e mecânicas que constituem as MUs e também são apresentados as estruturas musculares para melhor compreensão do tema, pois cada músculo contém uma quantidade específica de MUs. As MUs possuem diversos mecanismos e propriedades elétricas e existe uma relação direta entre número de MUs em um músculo e a amplitude das forças realizadas durante uma contração, ou seja, durante uma contração muscular ocorrerá o recrutamento das fibras musculares de acordo com demanda desejada. Essa proporção pode ser constatada pelo número destas fibras no músculo.

Dessa forma os grupos de MUs, que se constituem por um número elevado de fibras, só terá ativação quando o organismo recrutar um músculo maior ou uma conjunto muscular para realizar uma ação, ação diferente quando comparamos com grupos de menores de MUs, que são recrutados separadamente. A velocidade v de condução da contração elétrica está linearmente relacionada ao recrutamento limiar. Quando parametrizado uma MU pode-se dizer que as demais estruturas e MUs disponíveis acompanham as mesmas configurações. Os recrutamentos seguem uma ordem de distribuição, sendo ela contínua até que todas as MUs tenham atingido seus limites de atuação.

Os limites de recrutamento parecem seguir uma distribuição contínua com muitas MUs até atingir um pequeno limite de recrutamento e grandes quantidades de MUs sendo

recrutados apenas nos altos níveis de ativação. Esta ação pode ser validada pelo modelo exponencial apresentado por Fuglevand *et al.* (1992) que atribui os limites de recrutamento

$$\tilde{T} = \frac{e^{ai}}{100} \text{ com } a = \frac{\ln(100 \cdot \tilde{T}^*)}{n} \quad (1)$$

para MUs $i = 1, \dots, n$, onde \tilde{T}_i indica a mínima fração de toda força muscular no momento em que uma MU foi recrutada e \tilde{T}^* indica o recrutamento total. Podemos verificar também, a demonstração de Luca e Contessa (2012)), onde os limites podem ser determinados da seguinte forma pela Equação 2:

$$\tilde{T}_i = \frac{bi}{n} \cdot \frac{e^{ai}}{100} \text{ com } a = \frac{\ln\left(\frac{100 \cdot \tilde{T}^*}{b}\right)}{n}, \quad (2)$$

sendo b um fator de escala que influencia diretamente no processo de distribuição. Este modelo apresenta uma disposição mais gradual quando comparado com a Equação 1. Luca e Contessa (2012)) utilizaram este modelo para definir as características do músculo vasto lateral definindo $b = 20$. Para definição de umas das equações devemos considerar as características do músculo a ser investigado.

Com os limiares de recrutamento estabelecidos, as forças de contração de pico são calculadas como uma função dos limites de recrutamento, essa função é descrita pela Equação 3

$$P_i = 1 + \frac{\tilde{T}_i - \tilde{T}_1}{\tilde{T}^* - \tilde{T}_1} \cdot (P_n - 1) \quad (3)$$

Considerando ainda o modelo proposto por Luca e Contessa (2012)), a variação de pico na contração (P_n/P_1) é habitualmente maior, como por exemplo, $P_n/P_1 = 130$ para o primeiro músculo interósseo dorsal, como definido pelos autores. Dessa forma, garantindo proporcionalmente o número n de fibras musculares inervadas, influenciando principalmente nas forças das contrações geradas por uma MU (FUGLEVAND; WINTER; PATLA, 1993). Sendo assim, podemos modelar proporcionalmente a força de contração e o limiar de recrutamento, como apresentado na Equação 4,

$$\eta_i = \eta_{min} + \frac{P_i - P_1}{P_n - P_1} \cdot (\eta_{max} - \eta_{min}) = \eta_{min} + \frac{\tilde{T}_i - \tilde{T}_1}{\tilde{T}^* - \tilde{T}_1} \cdot (\eta_{max} - \eta_{min}). \quad (4)$$

A mesma condição pode ser utilizada para a velocidade de condução de contração elétrica v (VECCHIO *et al.*, 2017). Importante definir que Equação 4 determina a relação

entre as propriedades elétricas e mecânicas de uma MU, onde o número de fibras em determina a amplitude da resposta da contração no modelo apresentado. (ZHOU; RYMER, 2004) demonstraram que em alguns músculos, a amplitude da contração muscular pode estar relacionada à raiz quadrada da amplitude de contração de força; tal relação pode ser facilmente implementada, modificando a Equação 4 para forma da Equação 5

$$\eta'_i = \eta_{min} + \sqrt{\frac{P_i - P_1}{P_n - P_1}} \cdot (\eta_{max} - \eta_{min}) = \eta_{min} + \sqrt{\frac{\tilde{T}_i - \tilde{T}_1}{\tilde{T}^* - \tilde{T}_1}} \cdot (\eta_{max} - \eta_{min}). \quad (5)$$

Assim, como a relação entre o recrutamento das fibras musculares e a força resultante, existem outras estruturas que devem ser consideradas para funcionalidade do músculo esquelético, sendo elas as distribuições geométricas de unidades motoras e das fibras musculares, as taxas de disparo do potencial de ação, os instantes em que ocorrem esses disparos, e a propagação do potencial de ação no meio intracelular. Considerando a melhor compreensão das estruturas do EMG, será apresentado a modelagem da propagação do potencial de ação intracelular, conceito fundamental para disposição das regiões que são dispostas as interfaces.

A propagação do potencial de ação intracelular (IAP) no sistema de junção neuromuscular (NMJ) em uma fibra muscular ocorre ao longo das extremidades desta fibra, com capacidade de propagar em ambas direções. A fibra de disparo ativo responsável por essa ação constitui de uma fonte e um dissipador de corrente para sua distribuição, um impulso nervoso. Podemos analisar essa ação pela modelagem proposta por Dimitrov e Dimitrova (1998).

No modelo originalmente proposto por Dimitrov e Dimitrova (1998), este impulso distribuído $\hat{v}(z, t)$ é composto por pela onda de propagação e suas contribuições para o NMJ. Na formulação de (FARINA; MERLETTI, 2001), tem-se a Equação 6

$$\hat{v}(z, t) = \frac{d}{dz} [\psi(z - z_i - vt)p_1(z) - \psi(-z + z_i - vt)p_2(z)]. \quad (6)$$

Neste ponto, z indica a variável espacial ao longo da fibra muscular, z_i a localização do NMJ, p_1 e p_2 são as distâncias entre a zona de inervação e os tendões, respectivamente e v indica a velocidade de propagação do IAP. Além disso, a Equação 7

$$\psi(z) = \frac{d}{dz} V_m(-z), \quad (7)$$

indica o gradiente de voltagem através da membrana da fibra em toda sua extensão, onde a função $V_m(z)$ é um modelo para a forma de onda da membrana do tipo trans-fibra e pode ser escolhida involuntariamente para corresponder aos dados de simulação ou aquisição.

Estrutura e Mensuração sEMG

Plonsey e Barr (2007) descrevem os tecidos biológicos como condutores de volume, ou seja, um sistema de transmissão de campos elétricos ou magnéticos. Considerando que as mudanças fisiológicas ocorrem a longo prazo, é possível definir que os campos elétricos variáveis no tempo comportam-se de forma estática, desta forma são considerados quase estáticos. Consequentemente, os campos estáticos, os campos eletricos. E os condutores de volume fisiológico são considerados iguais aos gradientes negativos de um potencial escalar φ ,

$$\vec{E} = \nabla\varphi. \quad (8)$$

Pelas leis de ohm (PRESTON; SHAPIRO, 2012), a densidade da corrente J (corrente por unidade de área transversal) em um volume condutor é proporcional ao campo elétrico, ou seja, pela Equação 9

$$\vec{J} = \sigma \vec{E} = -\sigma \nabla\varphi. \quad (9)$$

onde σ indica a condutividade do meio. Definindo uma densidade de corrente amplamente distribuída I sob toda a região de interesse, a divergência da densidade de corrente é restringida pela Equação 10.

$$\nabla \cdot \vec{J} = I \quad (10)$$

Combinando as Equações 9 e 10 e assumindo um meio isotrópico homogêneo, tem-se uma difusão de potencial, como descrito na Equação 11:

$$\nabla\varphi = -\frac{I}{\sigma}. \quad (11)$$

Portando, o campo elétrico resultante de fontes nas camadas dos tecidos pode ser considerado por um modelo que abrange músculos planos e com maiores quantidade de fibras. As paredes musculares e as camadas de revestimento muscular são consideradas

planas e são revestidas por uma camada plana de gorduras e uma camada plana infinitamente estendida camada de pele. O tecido muscular é considerado anisotrópico, podendo definir a diferença entre a condutividade das correntes ao longo do eixo da fibra muscular e as correntes através das fibras musculares, enquanto o tecido adiposo e da pele são considerados isotrópicos. As fibras musculares são definidas para executar ao longo da direção z , com as dimensões x e z abrangendo o plano sobre a pele e a dimensão y sendo ortogonal ao plano da pele (FARINA; RAINOLDI, 1999). Uma região de origem da força é definida por \hat{I} , localizada em $(0, y_0, 0)$, os autores derivam a transformada de *Fourier* espacial bidimensional com distribuição de potencial na superfície da pele, definido como

$$\Phi(\hat{I}, \omega_x, \omega_z; y_0) = \frac{2\hat{I}}{\sigma_{m,p}} e^{-\omega_{ya}|y_0|} \cdot \frac{1}{(1+r_c)\cosh(\omega_y^+)v(\omega_y^+) + (1+r_c)\cosh(\omega_y^-)v(\omega_y^-)}, \quad (12)$$

com a redução, tem-se;

$$(\omega_y^+) = \omega_y(d_f + d_s), (\omega_y^-) = \omega_y(d_f - d_s), \omega_y = \sqrt{(\omega_x^2) + (\omega_z^2)}, \omega_{ya} = \sqrt{(\omega_x^2) + (r_a\omega_z^2)} \quad (13)$$

e

$$v(s) = \omega_{ya} + sr_m \tanh(s), \quad (14)$$

onde $\omega_x = 2\pi f_x$ e $\omega_z = 2\pi f_z$ implica nas frequências angulares espaciais com direções x e z , respectivamente. Os coeficientes

$$r_c = \frac{\sigma_s}{\sigma_f}, r_m = \frac{\sigma_f}{\sigma_{m,p}} \text{ e } r_a = \frac{\sigma_{m,f}}{\sigma_{m,p}}, \quad (15)$$

indicam as proporções das diferentes condutividades do tecido. Finalmente, y_0 descreve a profundidade da região no tecido muscular, d_f a espessura da camada de gordura e d_s a espessura da camada da pele.

A Equação 12 apresenta diretamente uma descrição analítica da função de transferência espacial bidimensional do condutor de volume, onde tem-se

$$H_{vc}(\omega_x, \omega_z; y_0) = \frac{1}{\hat{I}} \cdot \Phi(\hat{I}, \omega_x, \omega_z; y_0). \quad (16)$$

As aquisições de sEMG são geralmente produzidas de forma diferencial entre um conjunto de eletrodos. Devemos considerar grades regulares de eletrodos RÖS com

distâncias entre si de d_x e d_z , onde $R = R_a + R_b + 1$ e $S = S_a + S_b + 1$. As variáveis subscritas por a e b denotam o número de eletrodos diferenciais e de um eletrodo de referência escolhido arbitrariamente. Supõe-se que a grade esteja alinhada paralelamente ao eixo z . Atribuindo pesos $\zeta_{k\ell}$ para o eletrodos e assumindo que todos os eletrodos atinjam a mesma função de transferência, a função de transferência em uma distribuição de potencial de superfície para o potencial analisado é dada por Farina e Merletti (2001),

$$H_{ec}(\omega_x, \omega_z) = \sum_{k=-R_a}^{R_b} \sum_{\ell=-S_a}^{S_b} \zeta_{k\ell} e^{-j\omega_x k d_x} e^{-j\omega_z \ell d_z}. \quad (17)$$

Para a função de transferência de um único eletrodo, podem ser feitas suposições de modelo arbitrárias (MERLETTI; PARKER, 2004).

Concatenando as funções de transferência espacial H_{vc} do condutor de volume, H_{ec} do configuração do eletrodo e H_{ele} dos próprios eletrodos e a função de transferência global do sistema, tem-se

$$H_{glo}(\omega_x, \omega_z; y) = H_{vc}(\omega_x, \omega_z; y) \cdot H_{ele}(\omega_x, \omega_z) \cdot H_{ec}(\omega_x, \omega_z). \quad (18)$$

A partir disso, a distribuição de potencial 2D na superfície da pele pode ser calculada da seguinte forma:

$$\varphi(x, z, t) = \int_{\mathbb{R}} (i(x, y, z, t) *_{(x,z)} h_{glo}) dy = \int_{\mathbb{R}} \mathcal{F}\{i(\omega_x, y, \omega_z, t) \cdot H_{glo}(\omega_x, \omega_z; y)\}. \quad (19)$$

onde $i(\omega_x, y, \omega_z, t) = \mathcal{F}\{i(x, y, z, t)\}$ é a transformada de Fourier 2D da densidade de corrente a fonte $i(x, y, z, t)$ e $*_{(x,z)}$ indica a convolução 2D nas variáveis x e z . Para uma localização particular do eletrodo na superfície da pele e uma fibra muscular após um reta paralela à superfície da pele, a Equação 19 simplifica, que o potencial individual de ação de fibra (SFAPs) $\varphi(t)$ pode ser calculado numericamente (FARINA; MERLETTI, 2001; PETERSEN; ROSTALSKI, 2018).

Pode-se provar que, neste caso, o *kernel* de integração possui apenas singularidades removíveis, o que garante a convergência de um esquema de integração numérica (PETERSEN; ROSTALSKI, 2018). A solução numérica da (versão simplificada da) Equação 19 apresenta alto custo. Sendo necessário realizar este procedimento apenas uma única vez para cada fibra antes da aplicação, a fim de calcular os SFAPs de todas as fibras. Durante

a simulação, várias versões deslocadas desses SFAPs são sobrepostas para gerar o sEMG real.

$$EMG(t) = \sum_{i=1}^n \sum_{j=1}^{N_i} MUAP_i(t - t_{ij}), \quad (20)$$

onde n implica no número de MUs, N_i o número de eventos de disparo dessas MUs,

$$MUAP_i(t) = \sum_{j=1}^n \varphi_{ij}(t) \quad (21)$$

apresenta o potencial de ação da unidade motora, que é obtido pela soma das contribuições, isto é, os SFAPs, de todos os músculos pertencentes às fibras MU i . Os SFAPs simulados reproduzem corretamente a dependência da forma SFAP na posição relativa do eletrodo de registro e a profundidade das fibras musculares, bem como a distinção entre propagação e os componentes de sinal localizados no NMJ e nas duas extremidades da fibra.

2.3.2 Eletromiografia de Superfície de Alta Densidade (HDsEMG)

Nos últimos anos foram registrados um rápido avanço no desenvolvimento do HDsEMG e processamento de sEMG para extração de informações. No entanto, ainda existem lacunas a serem investigadas entre as técnicas disponíveis para pesquisa e suas aplicações clínicas (MERLETTI *et al.*, 2021; MERLETTI *et al.*, 2009; MERLETTI *et al.*, 2010; MERLETTI, 2010). Sendo assim, o HDsEMG, por apresentar uma interface multicanal aumentando a capacidade na aquisição do sEMG e conseqüentemente, gerando uma melhor resolução para processamento dos sinais de acordo com a sua arquitetura, é apresentado como principal estudo desta tese.

Uma das condições fundamentais para o HDsEMG está relacionado com matrizes de eletrodos que apresentam mínimas distâncias de um eletrodo para outro, a literatura apresenta um distanciamento de aproximadamente 10mm de um eletrodo ao outro e também apresenta uma área de baixo contato com aproximadamente $10mm^2$. Os eletrodos menores apresentam dificuldades técnicas na sua implementação, tais como: (i) alta impedância z durante o contato, (ii) incompatibilidade de alta impedância ΔZ , (iii) severos ruídos. Resultando em: (a) o efeito divisor de tensão e a conversão do modo comum, por exemplo, interferências das linhas de energia de 50/60 Hz, modo diferencial $\propto \Delta Z/Z_i$ onde Z_i é a entrada de impedância do amplificador durante as aquisições diferenciais, (b) menor

relação sinal–ruído (CATTARELLO; MERLETTI, 2016; PIERVIRGILI; PETRACCA; MERLETTI, 2014; SEARLE; KIRKUP, 2000).

O HDsEMG resulta na aquisição com informações bidimensionais das distribuições das atividades musculares sobre a pele, fornecendo um conjunto maior de informações sobre o músculo de interesse comparados aos sistemas de aquisição com eletrodos bipolares com e dimensionamento acima do classificado para as malhas de eletrodos no HDsEMG (STEGEMAN *et al.*, 2012). Os principais elementos que definem o HDsEMG são as dimensionalidades das matrizes dos eletrodos, o amplificador multicanal, as etapas de processamento de sinal e a interpretação e apresentação uma alta quantidade de dados.

As matrizes bidimensionais de eletrodos monopolares $NÖM$ com espaçamentos similares nos eixos x e y , amplificadores e ferramentas de gravação, tornam a aquisição e mapeamento do EMG viáveis e aplicáveis. Malhas de eletrodos HDsEMG adquirem sinais por eletrodos EMG monopolares em uma pequena região da superfície da pele. A processamento do HDsEMG em neuropróteses dependem de altos custos computacionais. Na aquisição HDsEMG, cada eletrodo pode ser mapeado com coordenadas x e y , fornecida pelas linhas e colunas das matrizes dos eletrodos (GIORGI, 2018). As interfaces HDsEMG acompanham os mesmos conceitos elétricos e mecânicos em relação ao EMG e o sEMG em sua estrutura. Sendo o sEMG conceito fundamental para HDsEMG por apresentar uma arquitetura não invasiva garante a eficiência e a usabilidade de matrizes com números elevados de eletrodos.

2.4 PRÉ-PROCESSAMENTO HDSEMG

Nesta Seção, serão apresentadas as técnicas aplicadas para a extração de características do sinal e o reconhecimento de padrões. Essas aplicações são necessárias para geração de classes por amostras utilizadas para alimentar os classificadores supervisionados.

2.4.1 Recursos para o Pré-processamento HDsEMG

Anteriormente, os potenciais de ação gerados pelos neurônios realizam contrações musculares que resultam no movimento dos membros. O sinal adquirido por um eletrodo consiste potencial de ação das unidades motoras (MUAPs) descrita nas Equações 20 e 21 de todas as MUs ativas e são detetáveis por eletrodos alocados na região desejada. Portanto,

os recursos podem ser extraídos dos sinais brutos para representá-los de forma informativa e não redundante. Essas técnicas são utilizadas para reduzir a dimensão de entrada em conjuntos gerenciáveis, mantendo suas informações de forma precisa e completa similar aos dados originais.

No entanto, os recursos que melhor representam os dados devem ser formulados para que o algoritmo funcione corretamente. Sendo assim os algoritmos de aprendizagem profunda, as *deep learning*, ganharam popularidade em relação aos algoritmos de aprendizado de máquina. O conceito de profundidade dos algoritmos de DP contém extratores de recursos em sua estrutura. Nesta tese, os recursos extraídos são utilizados para representar o sinais apenas para os algoritmos de aprendizado. Com base na pesquisa bibliográfica realizada, os seguintes recursos foram definidos e utilizados na extração de recursos da interface HDsEMG implementada.

Raiz do Valor Quadrático Médio

A raiz quadrada média (RMS) é o modelo que descreve um processo aleatório gaussiano modulado da amplitude constante da força e da contração não fatigante (PHINYOMARK; PHUKPATTARANONT; LIMSAKUL, 2012; NEGI; KUMAR; MISHRA, 2016). o RMS pode ser representado como:

$$RMS = \left(\frac{1}{L} \sum_{n=1}^L Z_n^2 \right)^{1/2}. \quad (22)$$

onde Z_n é o coeficiente wavelet e L é o comprimento total do coeficiente.

Valor Médio Absoluto

O valor médio absoluto (MAV) é um dos recursos sEMG mais populares que têm sido amplamente aplicados no reconhecimento de padrões em sEMG. MAV é definido como a média do valor absoluto do sinal, podendo ser expresso como (PHINYOMARK; LIMSAKUL; PHUKPATTARANONT, 2011; NEGI; KUMAR; MISHRA, 2016):

$$MAV = \frac{1}{L} \sum_{n=1}^L Z_n^2 |Z_n|. \quad (23)$$

onde Z_n é o coeficiente wavelet e L é o comprimento total do coeficiente.

Variância

A variância (VAR) é definida como uma média dos valores quadrados do desvio desta variável.

$$VAR = \frac{1}{N-1} \sum_{i=1}^N x_i^2. \quad (24)$$

Comprimento da Forma de Onda

Comprimento de onda (WL) é um recurso EMG frequentemente usado, que representa o comprimento cumulativo de forma de onda ao longo do tempo. O WL pode ser formulado como (HUDGINS; PARKER; SCOTT, 1993; NEGI; KUMAR; MISHRA, 2016):

$$WL = \sum_{n=1}^L |Z_n - Z_{n-1}|. \quad (25)$$

onde Z_n é o coeficiente wavelet e L é o comprimento total do coeficiente.

Frequência Média

Uma frequência média (MNF) pode ser calculada como a soma do produto do espectro de potência EMG e a frequência dividida pela soma total da intensidade deste mesmo espectro.

$$MNF = \frac{\sum_j^m f_j P_j}{\sum_j^m P_j}. \quad (26)$$

onde f_j é a frequência do espectro na frequência j e p_j é o espectro de potência em j .

Zero Crossing

O cruzamento zero (ZC) é uma medida de informação de frequência do sinal EMG definido no domínio do tempo (NEGI; KUMAR; MISHRA, 2016).

$$ZC = \sum_{i=1}^{N-1} [\text{sgn}(x_i x_{i+1}) \cap |x_i - x_{i+1}| \geq \text{limiar}]. \quad (27)$$

Comprimento Fractal Máximo

Comprimento fractal máximo (MFL) é um recurso EMG recente utilizado para medir a ativação de baixo nível das contrações musculares [28]. Matematicamente, MFL pode ser definido como:

$$MFL = \log_{10} \left(\sqrt{\sum_{i=1}^{N-1} (Z_{n+1} - Z_n)^2} \right). \quad (28)$$

Potência Média

A potência média (AP) do coeficiente wavelet é uma das características estatísticas para medir a energia e distribuição, podendo ser calculado como (SUBASI, 2013):

$$AP = \frac{1}{l} \sum_{n=1}^L Z_n^2 \quad (29)$$

onde Z_n é o coeficiente wavelet e L é o comprimento total do coeficiente.

2.4.2 Rotulação e Janelamento HDsEMG

As técnicas e algoritmos *Windows Length* e *Slide Windows* são uma abordagem padrão para na rotulação e no janelamento para o processamento de HDsEMG. A rotulação é responsável pela criação de classes em uma série temporal de sEMG, o *labelling*. Este método consiste em aplicar estimativas para identificar quando as MUs estão sendo recrutadas ou quando estão em repouso. Uma simples analogia seria, identificar quando o músculo está ligado ou desligado. Desta forma, aplica-se um algoritmo que determina uma linha de ponta a ponta no sinal e determina que todas as informações acima dela são pulsos validos de EMG. Esta linha é chamada de limiar ou *Threshold*, para realizar o *Threshold* é removido do sinal o valor médio sendo realizado retificação e a aplicação um filtro digital passa-baixa (FABIO, 1987; BOGEY; BARNES; PERRY, 1992; HODGES; BUI, 1996).

$$Threshold = \mu + J\sigma \quad (30)$$

Onde μ e σ são a média e o desvio padrão de um envelope durante um período de inatividade, o repouso. É onde J é uma constante.

Como conhecido, o EMG quando ainda não está filtrado, ou seja o sinal bruto não é considerado um sinal de entrada válido para aplicações com técnicas de reconhecimento de padrões. Isso ocorre por sua natureza aleatória. Para resolver isso, foi desenvolvido uma janela de análise de dados, o *Overlapping* e essa janela consiste no deslizamento de uma estrutura capaz de percorrer todo sinal no tempo. O comprimento desta janela pode ser definido de acordo com a necessidade do projeto a ser implementado e neste caso foi utilizado uma janela deslizante de 60 amostras, *samples* (IVES; WIGGLESWORTH, 2003).

Com o número de amostras definido o comprimento da janela T é multiplicado pela taxa de amostragem do sinal, resultando no número de amostras coletadas a partir deste processamento. Aplicados em HDsEMG os dados de classificação serão as amostras resultantes dos canais do sistema. Devemos considerar também a integração do *Overlapping* com as Transformadas de *Wavelets* Contínuas e Discretas.

Ao coletar dados sEMG, normalmente é necessário rotular onde, nos dados fluxo, onde um indivíduo está realizando cada movimento ou gesto, ou seja, para delimitar cada gesto. A delimitação pode ser alcançada tendo um especialista rotulando manualmente os dados com uma ajuda apropriada, como um vídeo do experimento com carimbos de data e hora. Devido a demanda de tempo, métodos automatizados são normalmente empregados. Métodos de malha aberta, como sinalizar X segundos após o assunto ser questionado assumir um gesto, são uma solução padrão. Métodos de malha aberta, no entanto, não são tão precisos em sua delimitação em comparação com métodos que incorporam informações, embora os métodos de malha aberta possam acelerar significativamente a rotulagem processo em relação a outras técnicas. Hartwell (2019) descrevem o desenvolvimento matemático para implementação do algoritmo de *labelling*, apresentado a seguir.

Se considerarmos Atzori *et al.* (2014) eles descrevem que a razão de verossimilhança generalizada (GLR) é aplicada para produzir prováveis delimitações para ciclos de descanso-movimento-descanso. Este método gera um limite mais próximo do que um especialista rotularia, mas potencialmente captura movimento não intencional ou indesejável efeitos transitórios.

Então, presume-se que a distribuição de sinais durante o movimento e quando no estado de repouso são Gaussianos, mas com parâmetros diferentes uns dos outros, que serão determinados como parte do processo (HYVÄRINEN; HURRI; HOYER, 2009). Esses

parâmetros são: onde $\theta_0 = (\mu_0, \sigma_0^2)$ é a distribuição de resto com média μ_0 e desvio padrão σ_0 . e onde $\theta_1 = (\mu_1, \sigma_1^2)$ é a distribuição do movimento com média μ_1 e padrão desvio σ_0 .

A suposição é feita de que a variância do movimento é maior do que o resto estado e que, como os dados são branqueados, as médias são 0.

A função de densidade de probabilidade correspondente para algum ponto x em qualquer distribuição Gaussiana é:

$$p(\theta, x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(x - \mu)^2}{2\sigma^2}\right], -\infty < x < \infty \quad (31)$$

Duas hipóteses podem então ser testadas para uma proposta de início e fim do movimento dentro do segmento: onde H_0 indica a inexistência de movimento: todos os dados estão em repouso ou seja, os dados são retirados da mesma distribuição. E onde H_1 indica que ocorre uma sequência de repouso movimento–repouso ou seja, os dados são extraídos das distribuições em sequência.

Correspondentemente, as probabilidades para um período de tempo de N amostras são:

$$H_0 \Rightarrow L(\theta_0) = p(\theta_0, x_{[0,N]}) \quad (32)$$

$$H_1 \Rightarrow L([\theta_0, \theta_1, \theta_0]) = p(\theta_0, x_{[0,r_1-1]})p(\theta_1, x_{[0,r_1,r_2]})p(\theta_0, x_{[0,r_2+1,N]}) \quad (33)$$

Onde r_1 e r_2 são o início e o fim do movimento, respectivamente. A probabilidade a proporção pode então ser expressa como:

$$\frac{L([\theta_0, \theta_1, \theta_0])}{L(\theta_0)} = \frac{p(\theta_0, x_{[0,r_1-1]})p(\theta_1, x_{[0,r_1,r_2]})p(\theta_0, x_{[0,r_2+1,N]})}{p(\theta_0, x_{[0,N]})} \quad (34)$$

Isso pode ser simplificado ignorando locais não marcados como movimento porque estes serão avaliados como 1, portanto, a função objetivo é:

$$\max \left[\prod_{k=r_1}^{r_2} \frac{p(\theta_1, x_k)}{p(\theta_0, x_k)} \right], 0 < r_1 < N, r_1 < r_2 < N \quad (35)$$

As distribuições θ_1 e θ_2 podem então ser estimadas a partir dos dados:

$$\hat{\mu}_0 = \frac{1}{(r_1 - 1) + (N - r_2 - 1)} \left(\sum_{k=1}^{r_1-1} X_k + \sum_{k=r_2+1}^N X_k \right) \quad (36)$$

$$\hat{\sigma}_0 = \frac{1}{(r_1 - 1) + (N - r_2 - 1)} \left(\sum_{k=1}^{r_1-1} (x_k - \hat{\mu})^2 + \sum_{k=r_2+1}^N (x_k - \hat{\mu})^2 \right) \quad (37)$$

$$\hat{\mu}_1 = \frac{1}{N} \sum_{k=r_1}^{r_2} x_k \quad (38)$$

$$\hat{\sigma}_1^2 = \frac{1}{N} \sum_{k=r_1}^{r_2} (x_k - \hat{\mu})^2 \quad (39)$$

Por fim, ao utilizar a razão de probabilidade logarítmica, o cálculo necessário pode ser reduzido e potencial para erro devido à precisão mitigada:

$$\ln \prod_{k=r_1}^{r_2} \frac{p(\theta_1, x_t)}{p(\theta_0, x_t)} = \frac{1}{2} \left[N_m \ln \frac{\sigma_0}{\sigma_1} + \frac{1}{\sigma_0^2} \sum_{k=r_1}^{r_2} (x_t - \mu_0)^2 - \frac{1}{\sigma_0^2} \sum_{k=r_1}^{r_2} (x_t - \mu_1)^2 \right] \quad (40)$$

$$N_m = r_2 - r_1 + 1 \quad (41)$$

Uma pesquisa exaustiva pode então ser usada para encontrar os pontos que produzem o maior probabilidade com simplificação adicional porque θ_1 é estimado a partir do dados:

$$\ln \prod_{k=r_1}^{r_2} \frac{p(\theta_1, x_t)}{p(\theta_0, x_t)} = \left[N_m \ln \frac{\sigma_0}{\sigma_1} + \frac{1}{\sigma_0^2} \sum_{k=r_1}^{r_2} (x_t - \mu_1)^2 - N_m \right] \quad (42)$$

Na prática, as suposições podem ser feitas na distribuição do resto, as anteriores introduzidas sobre a probabilidade de qualquer exemplo pertencer a uma classe particular e duração mínima do movimento adicionada para reduzir o espaço de pesquisa e refinar o previsões.

2.4.3 Análise dos Componentes Principais

O PCA é um algoritmo para redução dimensional (SUBASI, 2013; SMITH, 2002; NAIK *et al.*, 2016; SHLENS, 2014). O PCA visa encontrar uma projeção que melhor represente um conjunto de dados. Os dados de alta dimensão podem ser representados usando um conjunto de vetores de base. Para uma base de dados dimensional d \vec{x} , se os dados forem expressos por meio de vetores de base \vec{b}_i se apresentam da seguinte forma:

$$\vec{x} = \sum_{i=1}^d y_i \vec{b}_i \quad (43)$$

Em seguida, o PCA tenta representar os dados com número reduzido de dimensões m , de forma que o erro seja mínimo.

$$\vec{x} = \sum_{i=1}^m y_i \vec{b}_i + \sum_{i=m+1}^d a_i \vec{b}_i \quad (44)$$

onde, o erro é,

$$\Delta x = \sum_{i=m+1}^d (y_i - a_i) \vec{b}_i \quad (45)$$

Ao usar o erro quadrático médio para quantificar o erro da Equação 45, pode-se observar que,

$$\epsilon^2(m) = \sum_{i=m+1}^d \lambda_i \quad (46)$$

onde o i são os valores próprios correspondentes aos vetores próprios b_i , valores e vetores próprios representam as características principais de uma matriz. Dessa forma, para minimizar o taxa de erro, é necessário selecionar os vetores para gerar uma redução onde a soma dos valores para esses vetores serão mínimos. A escolha ótima do vetor de base são os vetores próprios da matriz de covariância. Para reduzir a dimensão, o erro é calculado seguindo a equação como uma razão da soma de todos os valores próprios e em seguida, os vetores principais são selecionados com base em uma certa taxa de erro de tolerância. O conjunto de dados original é projetado aos vetores de base com menor dimensionalidade.

2.4.4 Transformadas de Wavelets Contínuas e Discretas

No processamento de sinais sEMG, as DWT são amplamente implementadas. Assim como diversos métodos de análise do tempo-frequência, a DWT produz o sinal com representação do tempo-frequência, fornecendo informações de tempo e frequência simultaneamente. Na decomposição DWT, o sinal é decomposto em coeficientes de multirresolução usando filtros passa-baixo e passa-alto. Coeficientes DWT consistem de diferentes bandas de frequência. Os coeficientes com maior frequência são chamados de detalhe D , que são aplicáveis ao tempo. No entanto, os coeficientes em frequência mais baixa são nomeados de aproximação A , de forma que alcançam a melhor resolução de frequência (SUBASI, 2012). Matematicamente, a primeira decomposição de DWT pode ser escrita da seguinte forma:

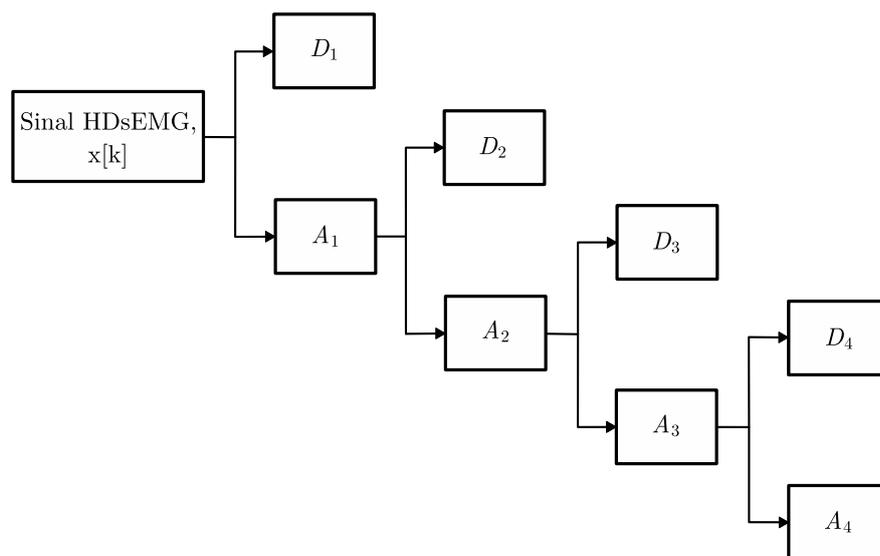
$$Z_{baixo} = \sum_{k=1}^L x[k] \cdot g[2n - k] \quad (47)$$

$$Z_{alto} = \sum_{k=1}^L x[k] \cdot h[2n - k] \quad (48)$$

onde Z_{baixo} e Z_{alto} são os coeficientes de D e de A , respectivamente, $x[k]$ é o EMG de entrada sinal, L é o comprimento do sinal e $h[.]$ e $g[.]$ são os filtros passa-alta e passa-baixa, respectivamente. De acordo com a literatura, o DWT, no quarto nível de decomposição pode fornecer resultados promissores em relação ao reconhecimento do padrões de sEMG (CHOWDHURY *et al.*, 2013; TOO *et al.*, 2019). Considerando isso, a decomposição de quarta ordem DWT foi implementada nesta tese.

A Figura 9 apresenta um diagrama com os procedimentos de decomposição wavelet de quarta ordem. No primeiro nível, o sinal EMG é decomposto em A_1 e D_1 . No segundo nível de decomposição, A_1 é decomposto em A_2 e D_2 . No processo de decomposição, a DWT divide pela metade os números de amostras e dobra a resolução de frequência (SUBASI, 2012). O processo de decomposição continua até o nível que o desejado seja alcançado. Para cada nível de decomposição, o sinal é sub-amostrado por um fator duplo. Uma das principais desvantagens da DWT é a seleção da wavelet materna. Para alcançar desempenho mais avançado, oito wavelets maternas são comumente utilizadas.

Figura 9 – Decomposição DWT de quarta ordem.



Fonte: Adaptado de Too *et al.* (2019).

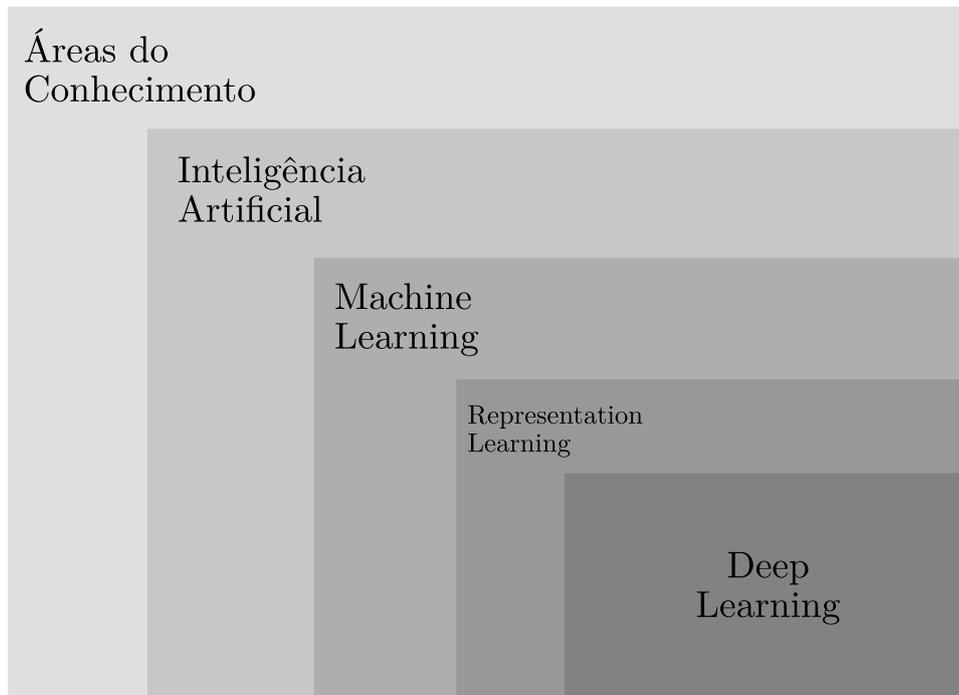
Para adquirir as informações dos coeficientes da wavelet, foram extraídos os recursos apresentados na Seção anterior, note que os recursos foram extraídos de cada A e D .

2.5 INTELIGÊNCIA ARTIFICIAL

Em todas as áreas do conhecimento e seguimentos da sociedade existem implementações de algoritmos capazes de observar, analisar e até mesmo interferir com ações dependendo de suas configurações e a inteligência Artificial se tornou indispensável na maioria de suas atuações e, cada vez mais, a informação e as diretrizes económicas e sociais se baseiam em IAs para seus gerenciamentos.

Na Figura 10 são apresentados por diagrama a relação entre IA, ML e DL. Observa-se, que os conceitos *machine learning* e a *deep learning* são subconjuntos das IAs. O diagrama descreve como as DPs se enquadram em um tipo de aprendizagem de representação, onde naturalmente consistem da implementação diversas técnicas de ML em seu funcionamento, sendo considerado uma espécie de IA. A principal diferença entre nos métodos de IA são as dependências do ser humano no estabelecimento de regras, ou na definição de recursos para solucionar um problema. A partir da camada de IA, a dependência humana no processo de aprendizagem diminui exponencialmente em direção às camadas internas (BORGES *et al.*, 2021).

Figura 10 – Diagrama representando as hierarquias na inteligência artificial.



Fonte: Elaboração do próprio autor.

2.5.1 Transferência de Aprendizado

O aprendizado de máquinas em um contexto geral reproduz como os seres humanos absorvem e processam o conhecimento com base na experiência. No entanto, os seres humanos possuem a capacidade de transferir o conhecimento de diferentes maneiras e formas. Se considerarmos um aprendizado comum, a simples ação de utilizar um *smartphone* por exemplo e para utilizar um *tablet* o indivíduo demandaria de quanto tempo para aprendizados adicionais em suas AVDs. Essa é uma reflexão importante (WAN *et al.*, 2021).

Considere a possibilidade de construir e desenvolver sobre os aprendizados e experiências anteriores, isso evita a necessidade de aprender algo desde o início. Otimização de custo e tempo é um tópico fundamental nos processos inteligentes atuais, sendo assim, o conceito responsável por manter essa condição é denominado *transfer learning* (TL) que traduzido para língua portuguesa refere-se à transferência de aprendizado (RAINA *et al.*, 2007; DO; NG, 2005).

Para a TL devemos considerar uma técnica de aprendizado de máquina onde o modelo treinado em uma respectiva tarefa é redirecionado em uma segunda tarefa que possua correlação. A TL como descrita anteriormente é a otimização que resulta em um progresso rápido ou com um desempenho aperfeiçoado durante a implementação do modelo da segunda tarefa. Elas estão relacionadas diretamente com problematizações de multitarefas e desvios de conceito e, portanto, não são exclusivamente implementadas em modelos de aprendizagem (TORREY *et al.*, 2010).

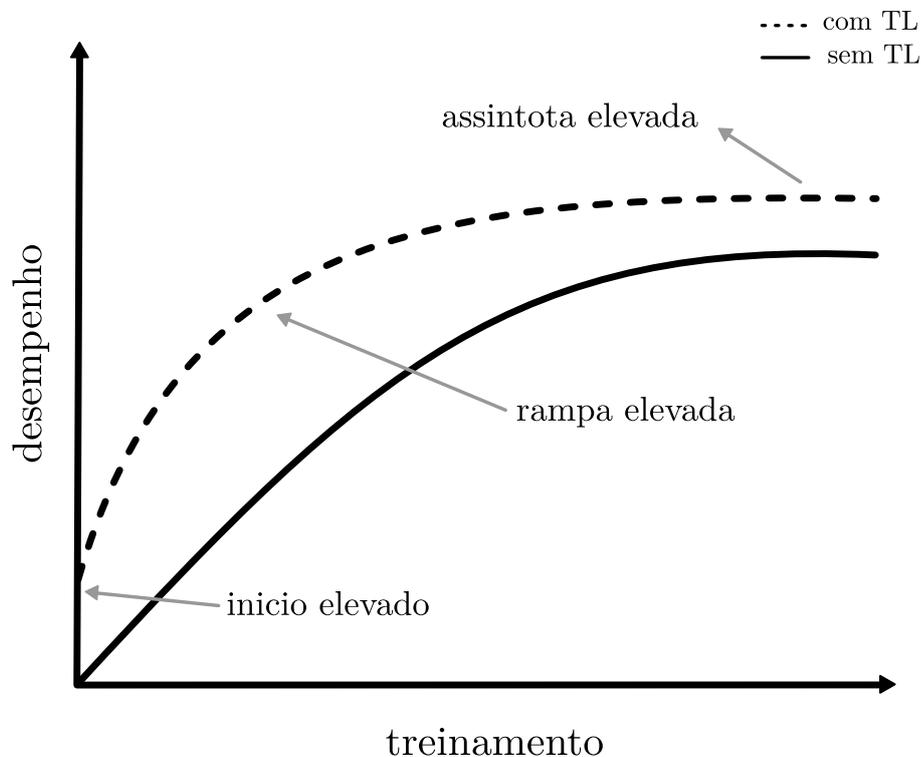
Segundo Torrey *et al.* (2010) para que as TLs funcionem em métodos de DP é necessário que os recursos do modelo proposto treinados na primeira tarefa sejam correlacionados. A técnica de utilizar TLs em modelos DP é chamada de transferência indutiva, neste momento os modelos propostos são restringidos utilizando ajustes de modelos de uma tarefa diferente, porém correlacionadas.

As TLs possuem duas abordagens principais: (a) desenvolvimento de uma abordagem do modelo e (b) um modelo pré-treinado. Em (a) são descritos os seguintes procedimentos: (i) selecionar a tarefa de origem, definindo um problema de uma modelagem preditiva com um grande fluxo de dados que se correlacionam nos dados de entrada e saída. (ii) reestruturar o modelo de origem onde o novo modelo deve ser mais eficiente que o modelo de origem. (iii) reutilizar o modelo, que consiste na transferência de aspectos eficientes para a segunda tarefa, todo modelo pode ser reutilizado se houver compatibilidade. (iv)

afinar o modelo, considerando todas as alterações o modelo escolhido pode precisar de ajustes tanto na entrada como na saída. Em (b) são aplicados os processos (i, ii e iii), esse método é considerado o mais comum em aplicações com DPs (GOODFELLOW; BENGIO; COURVILLE, 2017).

Torrey *et al.* (2010) descrevem os beneficiários na implementação por TL. A Figura 11 apresenta um gráfico descrevendo estatisticamente estes benefícios, onde apresenta uma habilidade superior no início do treinamento, uma taxa elevada durante o treinamento apontando uma rampa mais acentuada e uma habilidade superior no momento de convergência (assintota do vetor com TL) do treinamento.

Figura 11 – Gráfico apresentando os benefícios da implementação de *Transfer Learning*.



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

2.5.2 Deep Learning

Diversos algoritmos de aprendizados profundos *deep learning* (DP) foram projetados e implementados para lidar com problemas de aprendizados não supervisionados. Uma causa central das dificuldades com a aprendizagem não supervisionada é a alta dimensionalidade das variáveis aleatórias que estão sendo modeladas. Isso gera dois desafios distintos: o primeiro um desafio estatístico e o segundo um desafio computacional.

O desafio estatístico diz respeito à generalização onde o número de configurações para distinguir pode crescer exponencialmente com o número de dimensões de interesse, isso rapidamente se torna muito maior do que o número de exemplos que alguém pode possivelmente ter. O desafio computacional associado a distribuições de alta dimensão surge porque muitos algoritmos de aprendizado utilizam um modelo treinado que envolvem cálculos intratáveis e que crescem exponencialmente com o número de dimensões (LECUN; BENGIO; HINTON, 2015).

A DPs permitem ao computador construir conceitos complexos a partir de conceitos mais simples. O principal exemplo de um modelo de aprendizado profundo é o *feedforward deep network* ou a *multilayer perceptron* (MLP). Uma *perceptron* multicamadas é apenas uma função matemática que mapeia alguns conjuntos de valores de entrada para valores de saída. A função é formada pela composição de muitas funções mais simples. Podemos pensar em cada aplicação de uma função matemática diferente como fornecendo uma nova representação da entrada (DENG; YU, 2014).

É uma tarefa complexa sob a perspectiva computacional entender o significado dos dados de entrada quando ainda estão brutos. O mapeamento da função de um conjunto de *pixels* para a identidade de um objeto é muito complicado. Aprender ou avaliar esse mapeamento parece intransponível se abordado diretamente. O aprendizado profundo resolve essa dificuldade dividindo o mapeamento complicado desejado em uma série de mapeamentos simples aninhados, cada um descrito por uma camada diferente do modelo. A entrada é apresentada na camada visível, assim chamada porque contém as variáveis que podemos observar (DENG; YU, 2014).

Em seguida, uma série de camadas ocultas extrai recursos cada vez mais abstratos da imagem. Essas camadas são chamadas de camadas ocultas porque seus valores não são fornecidos nos dados, em vez disso, o modelo deve determinar quais conceitos são úteis para explicar as relações nos dados observados. As imagens aqui são visualizações do tipo de recurso representado por cada unidade oculta. Dados os *pixels*, a primeira camada pode identificar facilmente as bordas, comparando o brilho dos *pixels* vizinhos. Dada a descrição das arestas da primeira camada oculta, a segunda camada oculta pode facilmente pesquisar cantos e contornos estendidos, que são reconhecíveis como coleções de arestas. Dada a descrição da imagem pela segunda camada oculta em termos de cantos e contornos, a terceira camada oculta pode detectar partes inteiras de objetos específicos, encontrando coleções específicas de contornos e cantos (LECUN; BENGIO; HINTON, 2015).

A ideia de aprender a representação correta dos dados fornece uma perspectiva do aprendizado profundo. Outra perspectiva do aprendizado profundo é que a profundidade permite que o computador aprenda um programa em várias etapas. Cada camada de representação pode ser considerada como o estado da memória do computador após executando outro conjunto de instruções em paralelo. Redes com maior profundidade podem executar mais instruções em sequência.

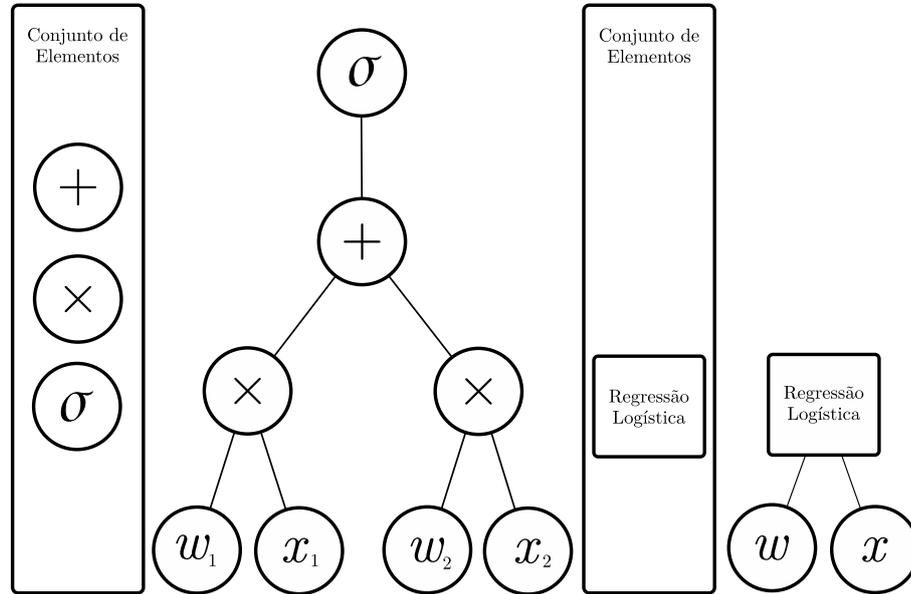
As instruções sequenciais oferecem grande poder porque as instruções posteriores podem referir-se aos resultados das instruções anteriores. De acordo com essa visão de aprendizado profundo, nem todas as informações nas ativações de uma camada codificam necessariamente os fatores de variação que explicam a entrada. A representação também armazena informações de estado que ajudam a executar um programa que pode dar sentido à entrada. Essas informações de estado podem ser análogas a um contador ou ponteiro em um programa de computador tradicional. Não tem nada a ver com o conteúdo da entrada especificamente, mas ajuda o modelo a organizar seu processamento.

Existem duas maneiras principais de medir a profundidade de um modelo (LECUN; BENGIO; HINTON, 2015). A primeira visualização é baseada no número de instruções sequenciais que devem ser executadas para avaliar a arquitetura. Podemos pensar nisso como o comprimento do caminho mais longo através do gráfico de fluxo que descreve como calcular cada uma das saídas do modelo dadas suas entradas. Assim como dois programas de computador equivalentes terão comprimentos diferentes dependendo da linguagem em que o programa foi escrito, a mesma função pode ser desenhada como um fluxograma com diferentes profundidades dependendo de quais funções serão usadas como etapas individuais no fluxograma. A Figura 12 ilustra como esta escolha de linguagem pode fornecer duas medidas diferentes para a mesma arquitetura (GOODFELLOW; BENGIO; COURVILLE, 2016).

E apresenta um diagrama com gráficos computacionais mapeando uma entrada para uma saída, em que cada nó executa uma operação. Profundidade é o comprimento do caminho mais longo da entrada à saída, mas depende da definição do que constitui uma possível etapa computacional. A computação representada nesses gráficos é a saída de um modelo de regressão logística $\sigma = (w^T x)$, onde σ é a função sigmóide logística. Se usarmos adição, multiplicação e sigmóides logísticos como os elementos de nossa linguagem de computador, então este modelo tem três profundidades. Considerando a regressão logística

como um elemento em si, então este modelo tem profundidade um (GOODFELLOW; BENGIO; COURVILLE, 2016).

Figura 12 – Diagrama representando o aprendizado profundo.



Fonte: Adaptado de Goodfellow, Bengio e Courville (2016).

2.5.3 Redes Neurais Convolucionais CNN

O elemento fundamental de uma rede neural artificial (RNA) é o neurônio artificial (MCCULLOCH; PITTS, 1943). O neurônio artificial é a função responsável por conduzir um argumento x com dimensionalidade arbitrária capaz de produzir um valor escalar x' , demonstrado na equação a seguir.

$$x' = f\left(\sum_{k=1}^n x(k)w(k) + b\right) \quad (49)$$

onde x' é a saída, também conhecido como axônio ou ativação, $x(k)$ e $w(k)$ são a entrada e o peso k : *th*, respectivamente o termo $a(k)w(k)$ é conhecido como dendrito e b é o viés (*bias*) e a $f(\cdot)$ é a função de ativação, As funções de ativação servem para trazer a não-linearidades ao sistema, para que a rede consiga aprender qualquer tipo de funcionalidade.

As redes neurais convolucionais (CNN) se sobressaem em relação a outras redes neurais pelo seu desempenho superior em entradas de imagens, voz e sinal de áudio. As CNN são constituídas em duas partes a extração de características contendo tipos principais camadas e uma RNA tradicional. As camadas e características são: a camada convolucional *Conv*, o processo de *padding*, a unidade de ativação linear retificada (ReLU),

as camadas de *pooling* e as camadas totalmente conectadas *fully connected layer* (FC). De acordo com a camada a CNN aumenta em sua complexidade, mapeando regiões cada vez maiores de uma imagem. As camadas anteriores permanecem realizando recursos simples, como cores e bordas. Sendo assim, conforme dados da imagem avançam pelas camadas da CNN, a mesma passa a reconhecer elementos ou formas do objeto até que finalmente aprende e identifica o objeto desejado (PINZÓN-ARENAS; JIMÉNEZ-MORENO; RUBIANO, 2020).

Para CNN reconhecimento e classificação as imagens, deve-se considerar que as entradas são estruturas de matrizes tridimensionais (3D) contendo altura, largura e profundidade. Essa dimensionalidade está relacionada ao tamanho da imagem, sendo assim a entrada é determinada pela quantidade de canais de cores. Uma imagem preta e branca como o padrão *grayscale* é representada como uma matriz 2D, em que cada posição da matriz representa um pixel da imagem. Os valores para cada elemento variam entre 0 (preto) até 255 (branco). Já uma imagem colorida é representada por uma matriz 3D onde é possível armazenar uma combinação das cores em três canais sendo eles o vermelho, verde e azul conhecido como *RGB* capaz de fornecer valores para cada pixel (ATZORI; COGNOLATO; MÜLLER, 2016; PINZÓN-ARENAS; JIMÉNEZ-MORENO; RUBIANO, 2020).

Matematicamente, uma convolução é uma operação linear originado de duas funções, gerando uma terceira conhecida como mapa de recursos. Analisando as CNN para imagens conceito para esta tese, podemos entender esse processo como um filtro *kernel* que transforma uma imagem de entrada. O kernel é uma matriz utilizada para operações de multiplicação de matrizes. Estas operações são aplicadas em N ciclos e em diferentes regiões da imagem. Em cada nova aplicação, a região é alterada por um parâmetro conhecido como *stride*. Normalmente o *stride* possui o valor 1, o que significa que a transformação foi aplicada em todos os pixels da imagem. O detector de recurso *kernel* se movimenta pelos campos receptivos da imagem, verificando se o recurso está presente. Este processo é conhecido como convolução (ATZORI; COGNOLATO; MÜLLER, 2016).

O detector de recursos é uma matriz pesos 2D, representando uma parte de toda a imagem. O tamanho do filtro é normalmente uma matriz 3×3 , determinando automaticamente o tamanho do campo receptivo. O filtro é aplicado em uma área da imagem e um produto escalar é calculado entre os pixels de entrada e o filtro. Este produto escalar é alimentado por uma matriz de saída. Onde o filtro modifica rapidamente, repetindo o processo até que o *kernel* tenha mapeado toda a imagem. A saída final da

série de produtos escalares da entrada e do filtro é conhecida como mapa de ativação ou recurso convolvido (ATZORI; COGNOLATO; MÜLLER, 2016).

Processo de Padding

O *Padding* é o processo onde pixels são adicionados ao redor da imagem antes da operação de convolução, de forma a manter a dimensionalidade na imagem resultante durante a operação. Esse processo é utilizado porque essas imagens resultantes podem conter elementos que facilitam a identificação da classe alvo para a rede. Uma CNN utiliza esse processo nas suas camadas iniciais, com a diferença de que a matriz de *kernel* não possui valores estáticos, ou seja eles são parâmetros treinados pelo algoritmo (NAM; HUNG, 2019).

Camadas de Pooling

o *Pooling* é um processo de *downsampling*. Consiste em um processo simples de redução da dimensionalidade do mapa de recursos. Essa transformação resulta na redução do tamanho da imagem. A principal função dessa operação no modelo, é de diminuir sua variância a pequenas alterações e também de reduzir a quantidade de parâmetros treinados pela rede.

Existem 3 operações diferentes de *Pooling* o *MaxPooling*, o *SumPooling* e o *AveragePooling*. Todas elas seguem o mesmo princípio e só se diferem na forma como calculam o valor final. A mais utilizada atualmente é a *MaxPooling*. A operação de *MaxPooling* retira o maior elemento de determinada região da matriz. Sendo assim, é realizado um deslizamento considerando um parâmetro de *stride* comparado com a operação de convolução para aplicação de uma nova operação (AKHTAR; RAGAVENDRAN, 2020).

A operação de *pool* mapeia um filtro por toda a entrada, mas a diferença é que esse filtro não tem pesos. Em vez disso, o *kernel* aplica uma função de agregação aos valores dentro do campo receptivo, preenchendo a matriz de saída. Existem dois tipos principais de *pool*: o *pooling* máximo, onde conforme o filtro se move pela entrada, ele seleciona o pixel com o valor máximo para enviar para a matriz de saída. Essa abordagem tende a ser usada com mais frequência em comparação com o *pool* médio. E o *pooling* médio,

onde conforme o filtro se move pela entrada, ele calcula o valor médio dentro do campo receptivo para enviar para a matriz de saída.

Embora muitas informações sejam perdidas na camada de *pool*, isso também traz vários benefícios para a CNN. Eles ajudam a reduzir a complexidade, melhorar a eficiência e limitar o risco de sobreajuste. Após cada operação de convolução, um CNN aplica uma transformação de *ReLU* ao mapa de características, introduzindo não linearidade ao modelo (AKHTAR; RAGAVENDRAN, 2020).

Camadas Totalmente Conectadas

Os valores de pixel da imagem de entrada não estão diretamente conectados à camada de saída em camadas parcialmente conectadas. No entanto, na camada totalmente conectada, cada nó na camada de saída se conecta diretamente a um nó na camada anterior. Esta camada realiza a tarefa de classificação com base nas características extraídas das camadas anteriores e seus diferentes filtros. Embora as camadas convolucionais e de *pooling* tendam a usar funções *ReLU*, as camadas FC geralmente aproveitam uma função de ativação *softmax* para classificar as entradas de forma adequada, produzindo uma probabilidade de 0 a 1 (BASHA *et al.*, 2020).

Para estrutura e modelamento matemático a camada convolucional (LECUN *et al.*, 1989; LECUN *et al.*, 1998), fornece o tensor de saída, originando seu próprio nome, gerando convolução do tensor de entrada com um ou mais *kernels* de tamanho fixo. Matematicamente, um tensor é um objeto algébrico que descreve uma relação multilinear entre conjuntos de objetos algébricos relacionados a um espaço vetorial. A importância e utilidade desta camada deu resultado na origem das CNN. O tipo de camada convolucional sendo considerada é a variante bidimensional, onde os *kernels* são do tamanho h, w, d onde h e w são hiperparâmetros, enquanto d é a profundidade do tensor de entrada, no entanto o princípio se generaliza para dimensões superiores (OLSSON, 2018).

A filtro de profundidade F diferente do tensor de profundidade de entrada d representa o número de *kernels* na camada. Para construir o tensor de saída. Para construir o tensor de saída, os resultados conhecidos como mapas de ativação da convolução, o tensor de entrada com cada *kernel* são empilhados ao longo da dimensão profunda. Uma

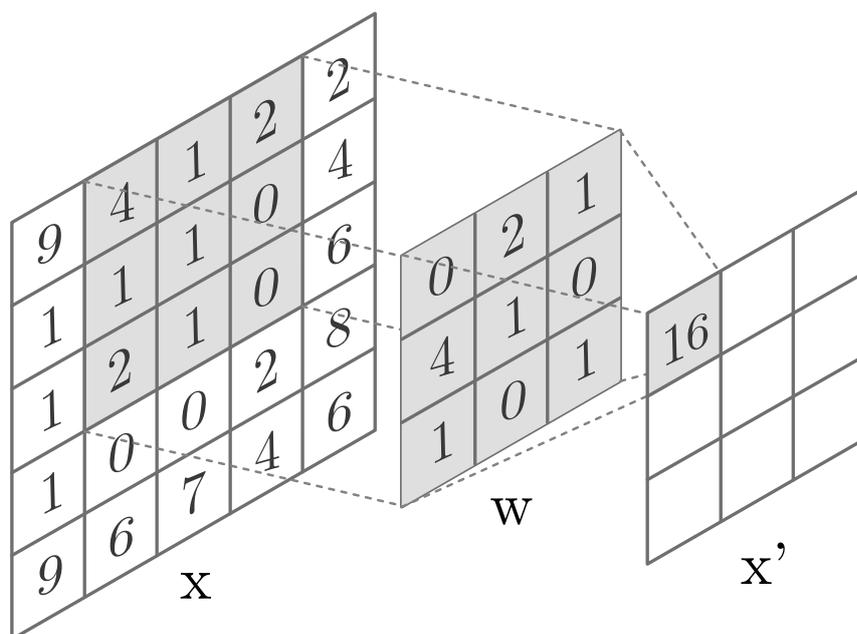
definição matemática completa da camada convolucional é apresentada a seguir (OLSSON, 2018).

$$X'(i, j, k) = \sum_{l=0}^{h-1} \sum_{m=0}^{w-1} \sum_{n=1}^d (W_k(l+1, m+1, n)X(S_y l + 1, S_x m + 1, n)) + b_k \quad (50)$$

Sendo x' é o tensor de saída, X é o tensor de entrada, W_k é o que pode ser aprendido, os pesos dos *kernels* e b_k é são o viés. A operação pode ser interpretada como um deslizamento dos *kernels* sobre o tensor de entrada onde cada *kernel* produz uma única camada profunda no tensor de saída. Contrariamente as camadas totalmente conectadas, onde o tamanho da saída destas camadas dependem do tamanho da entrada. Em princípio a camada conectada corresponde ao final da rede neural onde sua entrada é a saída da camada anterior e sua saída são N neurônios, com N sendo a quantidade de classes do seu modelo para finalizar a classificação (OLSSON, 2018).

A camada convolucional é, portanto, uma camada totalmente conectada com divisão de pesos e dessa forma o mesmo peso é repetido iterativamente ao longo de todo o tensor de entrada. Este racionamento de memória de peso é motivado pela suposição de que se um recurso é relevante para calcular em um índice espacial, também vale a pena calcular em todos os outros índices espaciais. A Figura 13 é exemplo de uma camada convolucional em ação.

Figura 13 – Representação da camada CNN em ação.



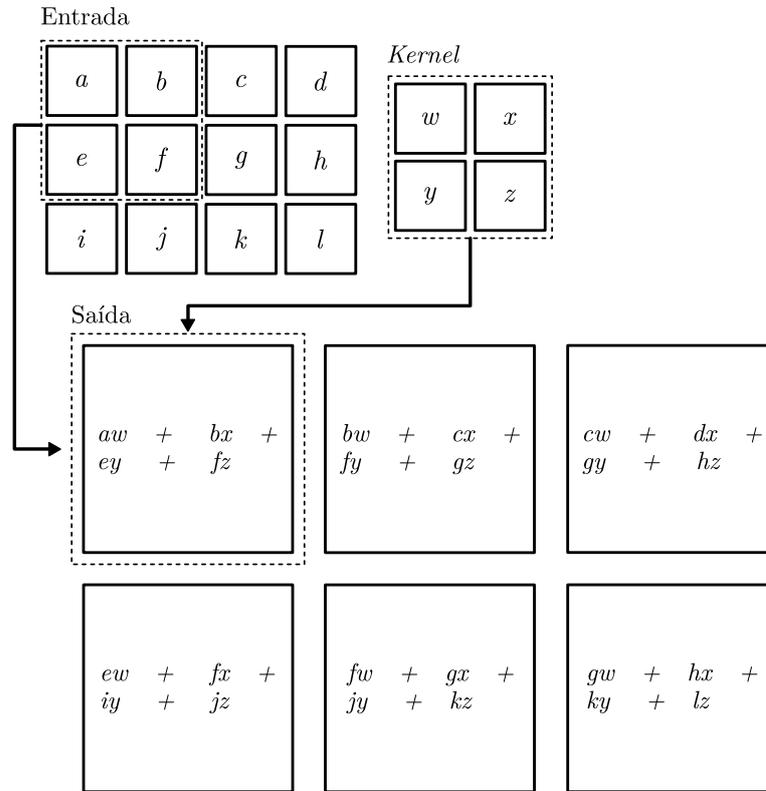
Fonte: Adaptado de Olsson (2018).

A propriedade comutativa da convolução surge porque invertemos o *kernel* em relação à entrada, no sentido de que à medida que m aumenta, o índice para a entrada aumenta, mas o índice no kernel diminui. A única razão para virar o kernel é obter a propriedade comutativa. Enquanto a propriedade comutativa é útil para escrever provas, geralmente não é uma propriedade importante de um sistema neural implementação de rede. Em vez disso, muitas bibliotecas de rede neural implementam um função relacionada chamada de correlação cruzada, que é o mesmo que convolução mas sem inverter o *kernel*.

Muitas bibliotecas de aprendizado de máquina implementam correlação cruzada, mas a chamam de convolução. No contexto do aprendizado de máquina, o algoritmo de aprendizado irá aprender os valores apropriados do kernel no local apropriado, então um algoritmo baseado na convolução com a inversão do kernel irá aprender um kernel que é invertido em relação para o kernel aprendido por um algoritmo sem a inversão. Também é raro para convolução para ser usado sozinho no aprendizado de máquina; em vez disso, convolução é usada simultaneamente com outras funções e a combinação dessas funções faz não comuta, independentemente de a operação de convolução inverter seu kernel ou não.

Para melhor compreensão da camada de convolução 2D sem inversão de *kernel*, são restringidas a saída para apenas as posições onde o *kernel* está inteiramente dentro da imagem. As caixas com setas indicam como o canto superior esquerdo do elemento do tensor de saída é formado pela aplicação do *kernel* correspondente a região superior esquerda do tensor de entrada. A Figura 14 representa a interação com o *kernel* e exemplifica a ação da camada convolucional demonstrada na Figura anterior.

Figura 14 – Representação exemplificada de uma convolução 2D.



Fonte: Adaptado de Goodfellow, Bengio e Courville (2017).

2.5.4 Normalização

Uma das etapas consideradas fundamentais no processo de treinamento é a normalização. A normalização pode fornecer uma aceleração no tempo de convergência e também dificulta a descoberta de mínimos com baixa qualidade. A normalização atinge isso garantindo que todos os recursos e entradas da rede apresentem o mesmo alcance, evitando que taxa de aprendizagem seja efetivamente ajustada proporcionalmente a um recurso de intervalo relativo. Este processo ajuda a garantir que a superfície de perda e erro resultante, sejam propícios para o aprendizado (LI *et al.*, 2017).

Um método padrão é normalizar todos os dados para significar 0 e a variância 1, com base na média e variância calculada a partir do conjunto de dados do treinamento:

$$x_i = \frac{x_i - \mu}{\sigma^2} \quad (51)$$

para que todos os dados de entrada x_i nos dados analisados. μ é o valor médio para cada recurso em x_i calculado apenas a partir dos dados de treinamento e σ é o desvio padrão também calculado apenas a partir de dados de treinamento. Uma abordagem alternativa

é a normalização em lote. A normalização em lote descrita por (IOFFE; SZEGEDY, 2015) normaliza cada saída de uma camada de maneira semelhante à Equação 51 para cada treinamento lote. Utilizar a normalização em lote tem os benefícios adicionais de fornecer regularização reduzindo a mudança interna covariável (LI *et al.*, 2017; JUNG *et al.*, 2019).

A mudança de covariação interna é a mudança na distribuição de ativações de rede devido a mudanças nos parâmetros de rede causadas pelo treinamento. Pode ser visto como o acoplamento entre as saídas das camadas anteriores e posteriores. Normalização em lote reduz esse acoplamento tornando a distribuição de ativação mais consistente. A normalização em lote também adiciona regularização a uma rede. A regularização vem do fato de que a normalização calcula a média e a variância de cada lote, o que efetivamente adiciona ruído ao processo (LIU *et al.*, 2018).

3 MATERIAIS E MÉTODOS

Neste capítulo serão apresentadas as metodologias aplicadas para implementação do sistema proposto, como parâmetros e protocolos utilizados na geração dos resultados obtidos. A interdisciplinaridade presente nesta área do conhecimento forneceu uma gama de informações sobre engenharia e medicina.

3.1 LEVANTAMENTO BIBLIOGRÁFICO

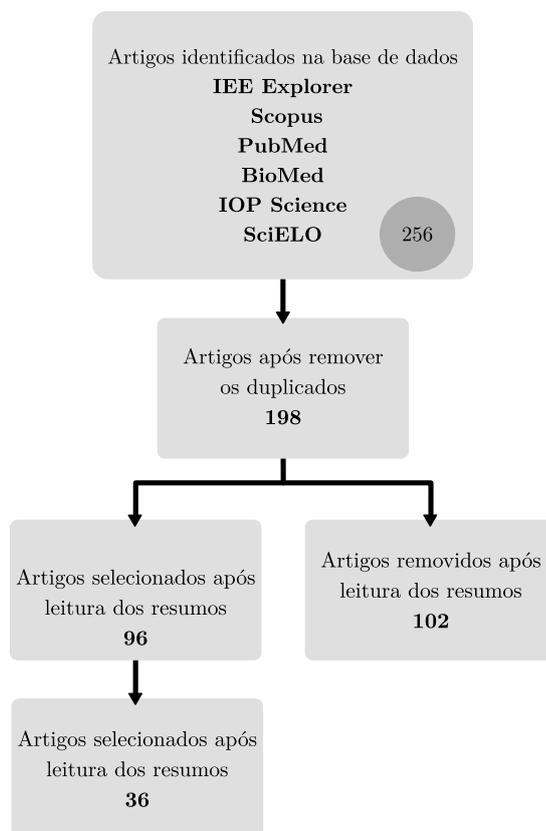
A pesquisa bibliográfica apresentada no estado da arte foi realizada nas bases *IEEE Xplorer*, *Elsevier Scopus*, *PubMed NCBI*, *BioMed Research International*, *IOP Science*, *SciELO*. Escolheu-se o idioma inglês e os critérios de pesquisa foram: *Transradial Neuroprosthesis*, *HDsEMG*, *Transfer Learning*, *Deep Learning*, *GoogleNet* e *VGG19*. O acesso a estes bancos de dados foram realizados pelo sistema de VPN da UNESP e da EPFL.

O levantamento bibliográfico inicial ocorreu entre os meses de janeiro a março de 2019, como parte integrante da proposta de doutorado. Foi realizada uma revisão sistemática para compreensão e desenvolvimento das tecnologias presentes nesta área e ao todo foram analisados 256 artigos apenas voltados a utilização de HDsEMG em análises do antebraço. Foram selecionados 36 artigos para formalização do estado da arte, apresentado na Seção 1.2 no Capítulo 1. Para esta investigação e a realização de uma filtragem nos artigos encontrados foi aplicado as diretrizes do método PRISMA–P (MOHER *et al.*, 2015).

Na primeira seleção foram excluídos artigos duplicados e artigos de outras categorias diferentes de periódicos completos, de jornais e revistas. O segundo critério utilizado para filtragem foi a leitura dos resumos dos 198 artigos que restaram, onde 102 artigos foram excluídos por não apresentarem o tema proposto e sim, apenas, palavras-chave em comum, totalizando 96 artigos selecionados.

Dos 46 artigos selecionados para leitura completa, foram destacados 36 artigos para descrição do estado da arte. Importante ressaltar, que as buscas quando limitadas nos termos *deep learning*, HDsEMG e membros superiores apresentam um número elevado de artigos disponíveis nos bancos de dados. Um diagrama representando a metodologia de classificação dos artigos é apresentado na Figura 15.

Figura 15 – Fluxograma PRISMA dos artigos investigados para o estado da arte.



Fonte: Elaboração do próprio autor.

A metodologia aplicada foi apresentada ao autor pelo grupo de pesquisa do *TNE-Lab*. Os temas eletromiografia de superfície, membro superior, controle de próteses de membros superiores, interfaces SNP, bidirecionalidade, classificadores binários supervisionado, neuroengenharia, procesos de extração de características e reconhecimento de padrão para biosinais, níveis de amputação do membro superior, fisiologia dos músculos do antebraço, processamento e instrumentação de biosinais, aprendizado de máquinas, inteligência artificial, dispositivos robóticos protéticos, mãos robóticas também foram investigados. Para aprofundamento nos tópicos estudados, realizou-se também pesquisa adicional em material de conteúdo básico através de livros texto que também fazem parte das referências registradas.

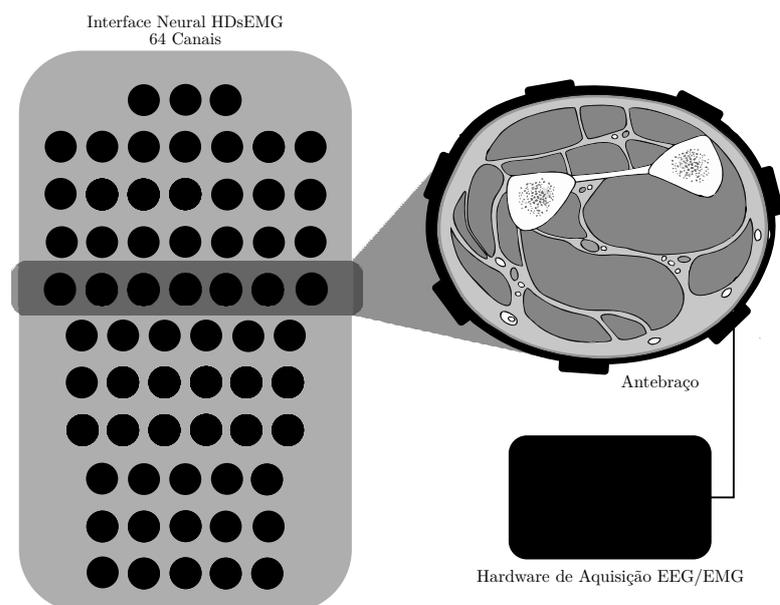
3.2 EQUIPAMENTOS E MATERIAIS

3.2.1 Interface Neural HDsEMG

A interface neural HDsEMG apresenta uma estrutura vestível capaz de envolver o antebraço, possuindo 64 eletrodos monopolares de cloreto de prata Ag/AgCl de $15 \times 20 \text{ mm}$ e dois eletrodos de referência, posicionados com uma distância de 20 mm entre eles. A disposição desses eletrodos foi projetada para englobar o maior número de músculos superficiais do antebraço, o *design* aplicado para distribuição dos eletrodos gerou quatro grupos de matrizes modulares: o primeiro grupo de eletrodos contém três linhas e cinco colunas, o segundo grupo contém três linhas e seis colunas, o terceiro grupo contém quatro linhas com sete colunas e o quarto grupo uma linha e três colunas.

Essa configuração está diretamente relacionada a estrutura fisiológica do antebraço e as diretrizes do SENIAM. A Figura 16 é uma representação da interface neural HDsEMG e a matriz representa a distribuição dos eletrodos no antebraço também são representados um corte transversal para visualização dos eletrodos distribuídos sobre a pele. Analisando a imagem deve-se considerar que a parte superior da matriz está compreendida a região proximal do antebraço, ou seja o próximo ao cotovelo e a parte inferior da matriz está compreendida a região distal do antebraço próximo ao punho.

Figura 16 – Representação da interface neural HDsEMG com 64 canais.

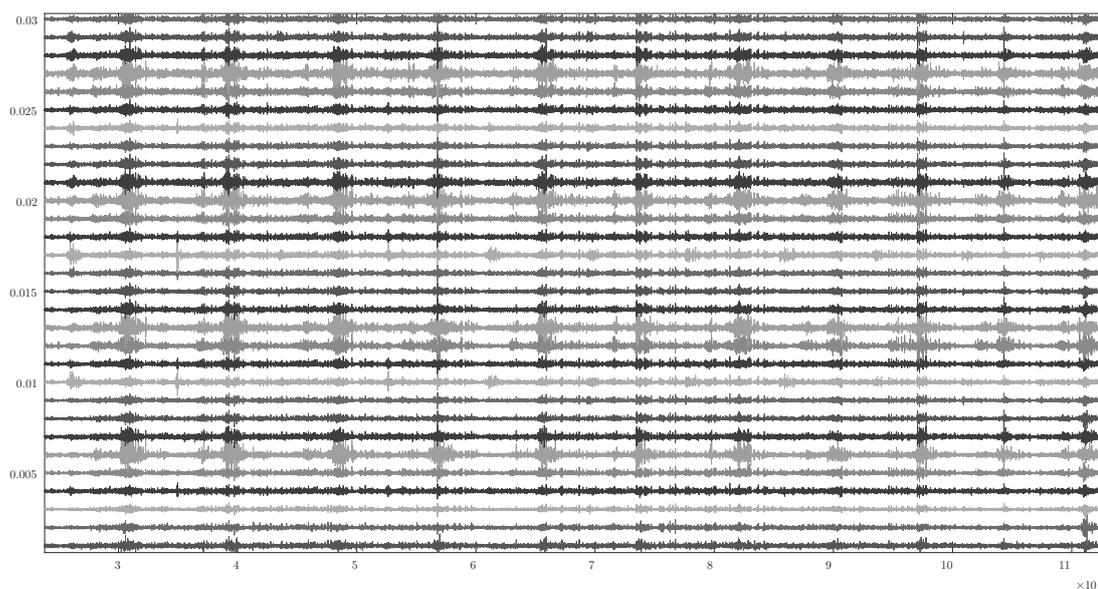


Fonte: Elaboração do próprio autor.

Na Figura 17 foram armazenados os momentos de realização das contrações musculares dos movimentos de desvio radial e desvio ulnar do punho de um voluntário. Considere na imagem movimentos intercalados entre os dois movimentos citados, sendo repetidos cinco vezes cada. Nos sinais apresentados podemos verificar a ação muscular, considerando a matriz de eletrodos pode-se também mapear quais músculos estão sendo recrutados no momento da contração muscular.

Essa possibilidade está diretamente relacionado a capacidade das interfaces HDsEMG, onde quanto maior o número de canais, maior será a identificação por regiões, analisando assim a ativação das MUs superficiais. Os sinais HDsEMG das figuras desta sessão já estão devidamente filtrados e os métodos de filtragem aplicados estão descritos neste capítulo.

Figura 17 – Gráfico HDsEMG com canais dos movimentos de Desvio Radial e Ulnar do punho.

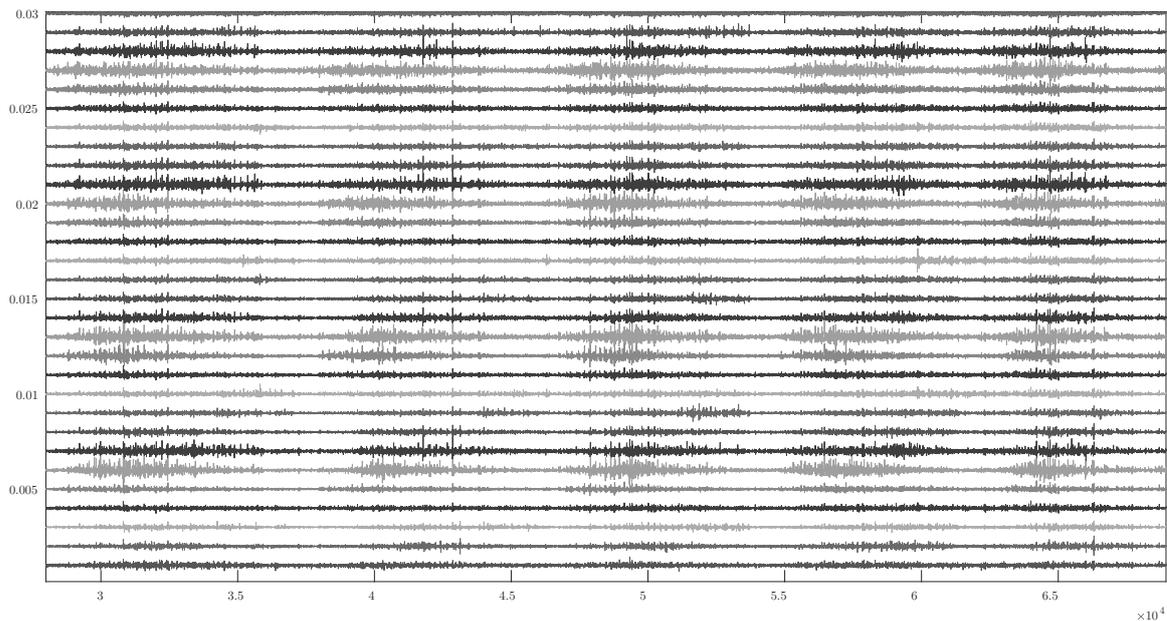


Fonte: Elaboração do próprio autor.

A Figura 18 apresenta o mesmo conceito da figura anterior, onde é possível observar as contrações musculares de um voluntário do movimento de circundação do punho em sentido horário. Essas figuras apresentaram apenas 30 canais, para favorecer a visualização e compreensão das mesmas.

Podemos observar também os instantes de ativação, dentro do mesmo movimento, pois existem tempos diferentes de ativação dependendo do músculo recrutado. Os espaços relativamente vazios entre os movimentos é o momento de inércia do voluntário, onde não há movimentação do antebraço, sendo assim as regiões de repouso.

Figura 18 – Gráfico HDsEMG com canais do movimento de circundação do punho.

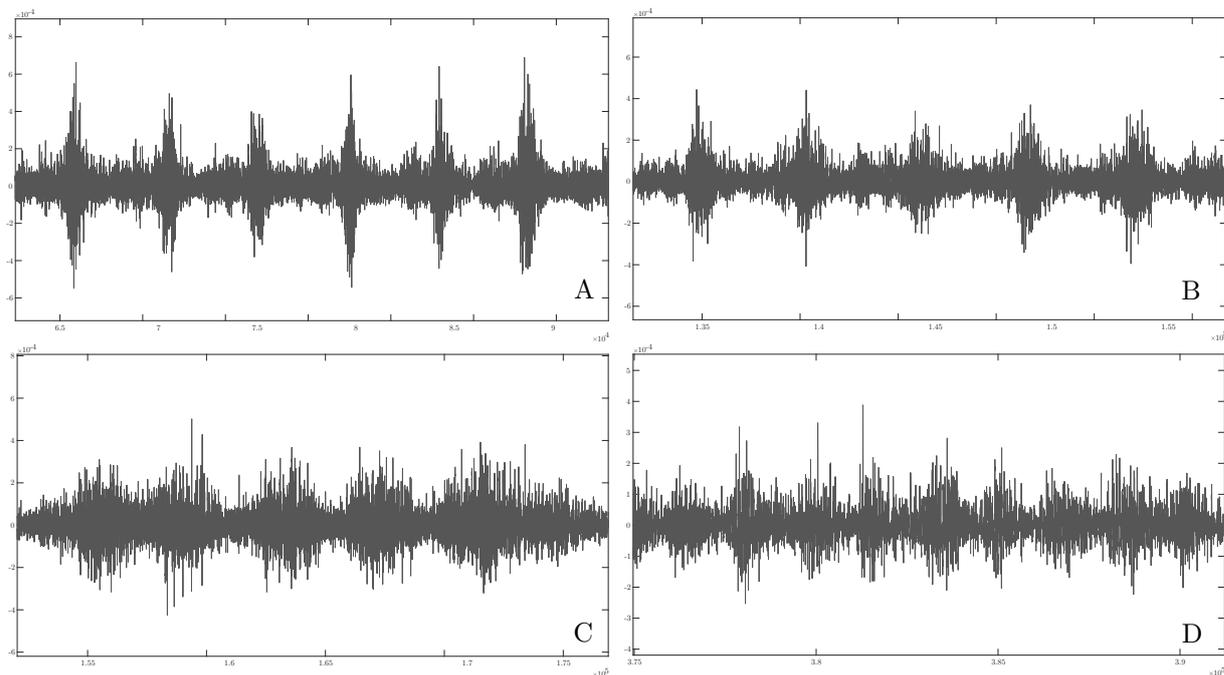


Fonte: Elaboração do próprio autor.

Na Figura 19 apresenta os sEMG dos quatro grupos de movimentos da mão e do antebraço de um voluntário e estão dispostos da seguinte forma: o sinal A são as repetições intercaladas dos movimentos de flexão e hiperextensão do punho, o sinal B são as repetições intercaladas dos movimentos de desvio radial e ulnar do punho, o sinal C são repetições intercaladas dos movimentos de circundação do punho nos sentidos horário e anti-horário respectivamente e o sEMG D apresenta os movimentos de flexão interfalângica e metacarpofalângicas sem o polegar e fechamento da mão.

Importante considerar que nem sempre pode-se identificar visualmente nos sinais sEMG as contrações realizadas e, desta forma, são necessários a aplicação métodos estatísticos e computacionais para o processamento e extração de características dos sinais.

Figura 19 – Sinais sEMG dos 4 grupos de movimentos selecionados.



Fonte: Elaboração do próprio autor.

3.2.2 Software MATLAB

Para interpretação, análise e manipulação dos dados adquiridos durante essa investigação foram fundamentais a utilização de softwares para traduzir, interpretar e converter informações físicas em informações digitais com aplicação de algoritmos próprios para cada necessidade, um dos principais recursos no desenvolvimento de sistemas inteligentes são as plataformas de desenvolvimento numérico e computacional essas arquiteturas são responsáveis pelo pré-processamento e processamento de todos os dados, devemos considerar também as linguagens de programação que devem satisfazer a implementação de todos os recursos para funcionamento do sistema projetado.

Um das dessas plataformas e linguagem é o MATLAB abreviação de *MATrix LABratory* linguagem de programação multiparadigma proprietária desenvolvida pela *MathsWork* empresa norte americana especializada em softwares para computação matemática e numérica. O MATLAB foi utilizado como a principal ferramenta para filtragem, estruturação e pré-processamento e processamento em todos os processos desta tese. As classificações e treinamentos foram desenvolvidos com o *Deep Learning Toolbox* conjunto de recur-

presentes no ambiente MATLAB e também recursos como as classes *DAGNetwork* e *SeriesNetwork*, para a estruturaração e arquitetura dos modelos propostos.

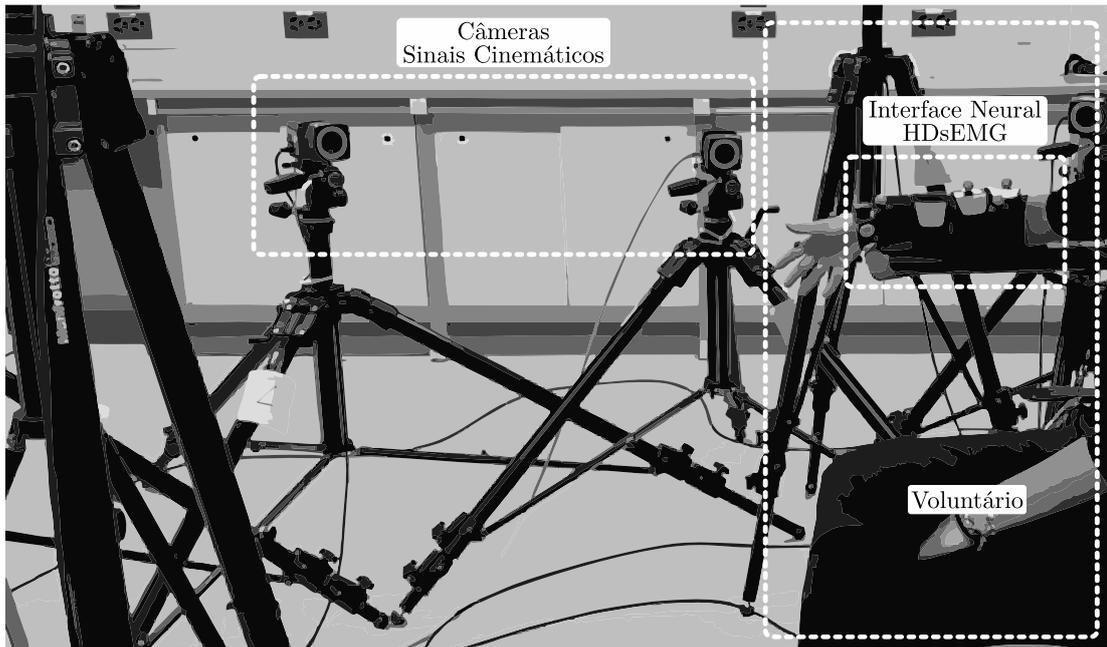
3.2.3 Hardware para aquisição de sinais cinemáticos

Foram utilizadas seis câmeras optoeletrônicas do sistema de aquisição cinemática o *Vicon*, *Vicon Motion System*, que nesta implementação foram aplicados para capturar os movimentos exercidos pelas mãos e a integração deste sistema contribuiu para a validação dos algoritmos de extração e classificação aplicados na interface HDsEMG. Os dados cinemáticos foram adquiridos com uma frequência de amostragem de $1000Hz$. Para obter os movimentos do punho e da mão, sendo que dez marcadores reflexivos foram distribuídos no antebraço para definir o modelo de aquisição definido pelo software do *vicon*.

A necessidade de criar um banco com dados cinemáticos em conjunto com o banco de dados HDsEMG descrito nesta Seção, é um comparativo em tempo real dos dados EMG coletados pela interface neural HDsEMG implementada. Utilizar dados cinemáticos para rotular biosinais tem sido utilizado por décadas como citado nos estados da arte. No entanto, novas técnicas de rotulação e sobreposição permitem realizar essas ações digitalmente. Os dados cinemáticos armazenados não foram inseridos nos algoritmos de validação e classificação. Eles foram utilizados apenas como comparação para validar os dados HDsEMG.

A Figura 20 apresenta uma ilustração das disposições das câmeras de aquisição dos sinais cinemáticos e também apresenta o posicionamento dos voluntários durante as aquisições da interface neural HDsEMG, definidos pelo protocolo experimental descrito na próxima Seção.

Figura 20 – Ilustração das aquisições dos sinais cinemáticos e da interface neural HDsEMG.



Fonte: Elaboração do próprio autor.

3.3 PROTOCOLO EXPERIMENTAL

Esta tese contém um protocolo experimental implementado em todos os processos de aquisições realizados durante essa investigação. O protocolo experimental está definido para as etapas de aquisição dos sinais da interface neural HDsEMG e aquisição dos sinais cinemáticos juntamente com os voluntários disponíveis para as coletas programadas. Todas as aquisições deste trabalho ocorreram nas instalações do TNElab situado no *Campus Biotech*, sob a supervisão e suporte do comitê de ética local o *Swiss Association of Research Ethics Committees, SWISSETHICS* no *Swiss Ethics Committees on research involving humans*, já implementado quando o autor ingressou na EPFL para realização do doutorado com período de intercâmbio.

3.3.1 Setup de Aquisição HDsEMG

A arquitetura para aquisição e armazenamento dos sinais HDsEMG são continuados pelo hardware *EEGO Mylab* da empresa *Ant Neuro* de 64 canais, desenvolvido para aquisição de sinais EEG e a interface neural HDsEMG. Os dados foram coletados na

frequência de amostragem de $2000Hz$ e posteriormente filtrado com passa alta de $10Hz$ e o *design* de um filtro *Butterworth* de quarta ordem.

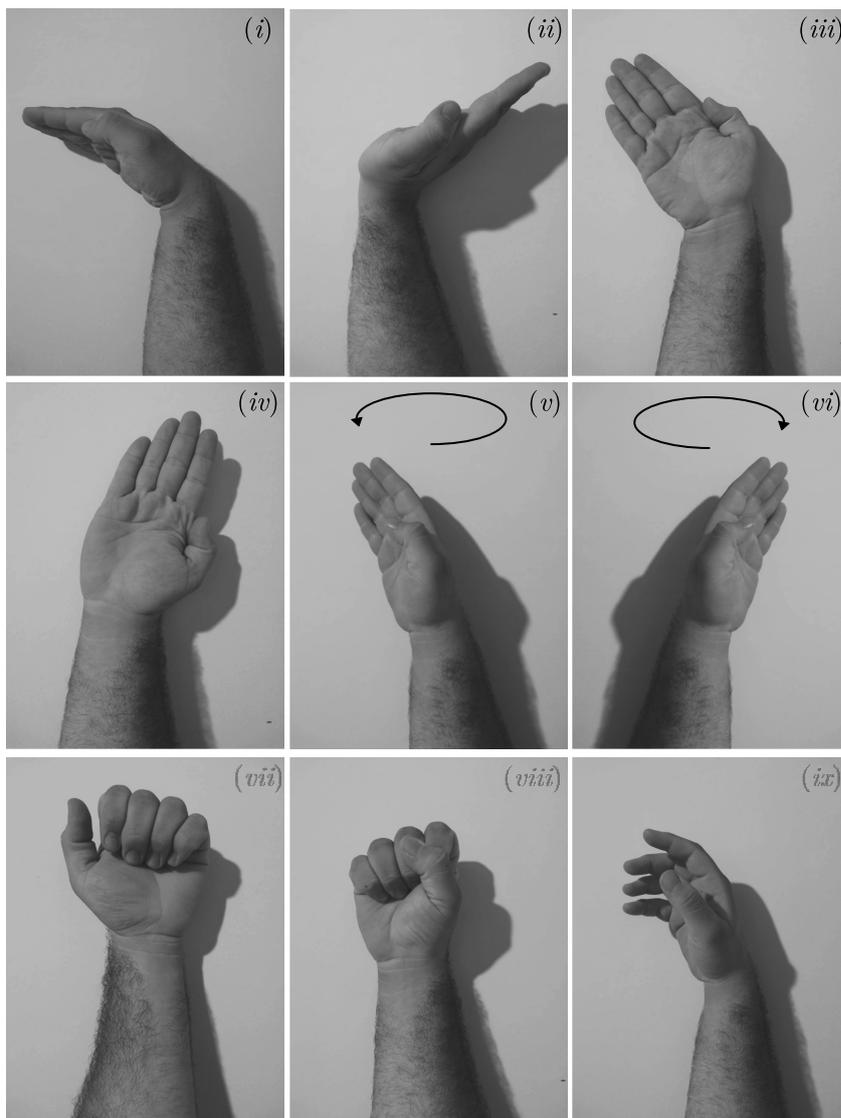
3.3.2 Construção do Banco de Dados

O banco de dados desta investigação consiste nos dados de entrada para os classificadores durante os treinamentos e possui características estruturais compatíveis para capacidade e necessidade dos classificadores. Foram definidos nove movimentos para aquisição do HDsEMG, sendo eles classes validas para alimentação durante os treinamentos.

As classes são, (i) os movimentos de flexão do pulso (MFP), (ii) hiperextensão do pulso (MHP), (iii) movimentos de desvio radial (MDR), (iv) desvio ulnar (MDU), (v) movimentos de circundação do pulso no sentido horário (MCH), (vi) circundação do pulso no sentido anti-horário (MCA), (vii) movimentos de flexão interfalângiana e metacarpofalângianas (MFI) sem o polegar, (viii) fechamento da mão (MFM) e (ix) a classe de repouso (RPO), momento de inércia do antebraço.

Todos os movimentos foram repetidos em cinco séries com cinco repetições por movimento, totalizando assim 25 repetições armazenadas dos 64 canais do HDsEMG. Os eletrodos de referência foram colocados próximo ao cotovelo. Os movimentos escolhidos, representam aproximadamente 85% de toda contração muscular do antebraço, analisando principalmente os músculos superficiais. Na Figura 21 são representados por fotografias os movimentos de punho descritos.

Figura 21 – Fotografia dos movimentos realizados pelo antebraço.



Fonte: Elaboração do próprio autor.

3.3.3 Dados dos Voluntários

Foram recrutados nove voluntários hígidos, homens e mulheres sendo adultos entre 18 e 30 anos. Para a aquisição de um banco de dados com nove movimentos da mão e do antebraço. Os voluntários permaneceram sentados durante todo o protocolo de aquisição. A interface HDsEMG foi colocada no membro de domínio do indivíduo. Com a interface posicionada no antebraço do voluntário, inicia-se o processo de aquisição e armazenamento do sinal. Os *hardwares* textitEEGO Mylab e as cameras *Vicon* são acionados simultaneamente.

Os critérios de inclusão e exclusão foram definidos e organizados da seguinte forma: (a) os critérios de inclusão estabelecem pessoas saudáveis maiores de 18 anos, voluntários e cientes dos riscos e desconfortos associados ao teste. Além disso, as pessoas que são voluntárias devem ser capazes de ler, compreender, assinar um termo de consentimento livre e esclarecido e (b) os critérios de exclusão estabelecem pessoas com deficiências cognitivas, que não podem ser voluntárias, considerando que leitura, compreensão dos testes e consentimentos são fatores fundamentais.

Considerando estas definições pelo protocolo, serão considerados para estruturação e organização dos dados os seguintes parâmetros; pontos ergonômicos do antebraço, descrição dos testes e realização dos testes e os pontos antropométricos para localização das MUs para os canais da interface HDsEMG. Os pontos foram localizados de acordo com os padrões do SENIAM. Os músculos foram selecionados de acordo com sua relevância clínica para a aquisição. Os voluntários foram orientados a permanecerem sentados apoiando o membro superior com a interface neural no encosto da cadeira, deixando o antebraço com um ângulo de 90° em relação ao braço, de forma confortável.

Na descrição dos testes são considerados os ambientes e estruturas utilizados. Foram realizados na sala de aquisições de biosinais do TNELab. Após a instrumentação de cada voluntário, o pesquisador se posicionou no ambiente de acionamento dos hardwares de aquisição.

Os voluntários foram orientados a realizar dois testes: (1) teste estático e (2) teste com os movimentos definidos pelo protocolo. O teste estático consiste na aquisição de sinais do voluntário em repouso. Neste momento a interface e o hardware registram o comportamento do sistema quando não há ativações musculares e os testes com movimentos consiste na realização de movimentos definidos para movimentação da mão e do punho. Os indivíduos foram solicitados a realizar os movimentos de maneira a tentar repetir as mesmas velocidades e ângulos durante as repetições do mesmo movimento.

3.4 MODELOS CNN IMPLEMENTADOS

Como apresentado anteriormente as DPs são técnicas de aprendizado de máquina que ensinam os computadores a realizarem tarefas naturais para os seres humanos, como o aprendizado por experiência. As DPs são as principais tecnologias para atuação de sistemas médicos e hospitalares inteligentes, pesquisas com neuropróteses e de veículos autônomos

por exemplo, podendo o robô cirurgião ou o veículo reconhecer milhares de informações fisiológicas para protocolos de segurança e no trânsito para reconhecer sinais como dos semáforos, distinguir um pedestre de um poste de luz. Nas DPs, um modelo computacional aprende a realizar tarefas de classificação diretamente de imagens ou também de textos e de sons.

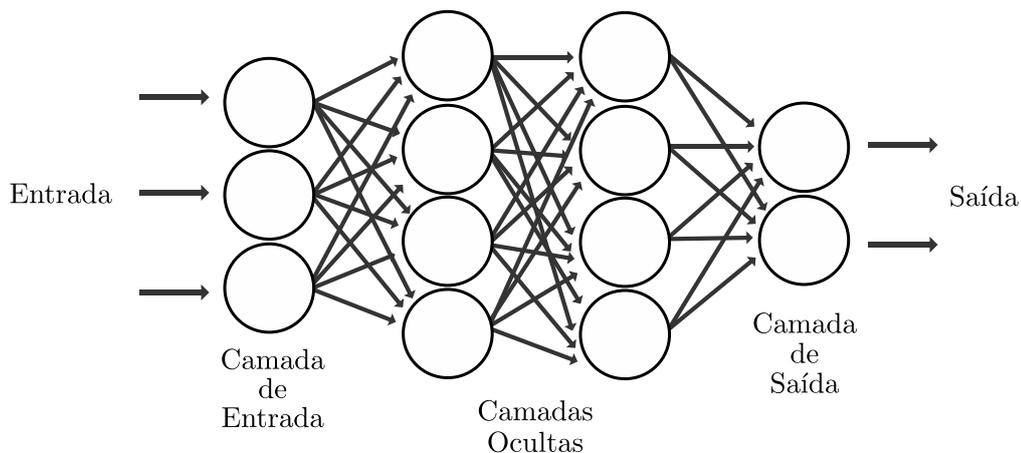
Os modelos DP podem exceder as vezes o desempenho do nível humano, importante compreender que desempenho e custo estrutural devem ser equivalentes para superar todo organismo humano, mas isso ainda não ocorre. Os modelos são treinados utilizando uma gama de dados rotulados e arquiteturas de redes neurais com múltiplas camadas. As DPs dependem diretamente destas grandes quantidades de dados rotulados. Por exemplo, no desenvolvimento de carros autônomos são necessários milhões de imagens e milhares de horas de vídeo gravados para realização dos treinamentos para aprendizagem.

As DPs, mesmo com desempenho elevado, ainda necessitam de um poder computacional substancial. As GPUs de alto desempenho apresentam arquiteturas paralelas eficientes as DPs. Quando implementados com *clusters* ou computação nas nuvens, permitem que os profissionais de desenvolvimento reduzam o tempo de treinamento para uma DP de dias para horas ou até mesmo minutos.

A maioria dos métodos de DPs utilizam arquiteturas de redes neurais já consolidadas, sendo assim os modelos de DP costumam ser chamados de redes neurais profundas. A nomenclatura *profundo* é adotada para se referir ao número de camadas ocultas na RNA. As RNAs tradicionais normalmente são constituídas de 2 a 3 camadas ocultas apenas, enquanto as DPs podem apresentar de 150 a mais camadas ocultas.

Os modelos de DPs são treinados utilizando grandes conjuntos de dados rotulados e arquiteturas de RNAs que aprendem recursos diretamente dos dados obtidos, resultando assim na não necessidade da extração manual de características e recursos. As RNAs, são organizadas em camadas que constituem um conjunto de nós interconectados e essas redes podem conter dezenas ou centenas de camadas ocultas. A Figura 22 apresenta a ilustração de uma rede neural artificial, conceito base para arquiteturas das DPs utilizadas nesta tese.

Figura 22 – Representação de uma rede neural artificial.

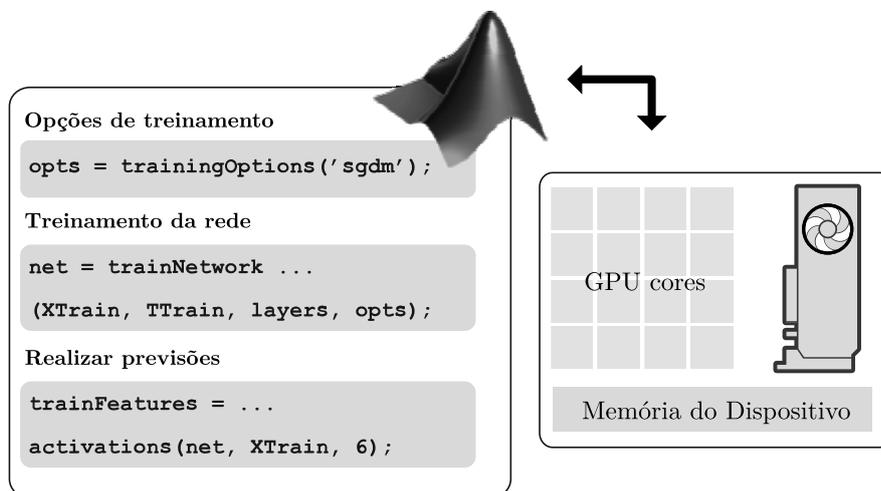


Fonte: Elaboração do próprio autor.

Os tipos mais conhecidos e implementados de DPs são as CNNs. Como descrito anteriormente as CNNs envolvem recursos aprendidos com dados de entrada e utiliza camadas convolucionais 2D, resultando assim em uma arquitetura adequada para o processamento de dados 2D, eficiente e adequado para treinamento com imagens. Por condição das CNNs funcionarem extraíndo recursos diretamente das imagens obtidas.

Os recursos relevantes não são pré-treinados. Eles são aprendidos enquanto a rede treina toda a coleção de imagens presentes. Portanto, a extração automatizada de recursos torna os modelos de DPs altamente precisos para as tarefas de visão computacional, como classificação de objetos, biosinais, sons e etc. A Figura 23 apresenta um diagrama exemplificando o ambiente de comando do MATLAB para o comando de cada etapa no treinamento do modelo implementado.

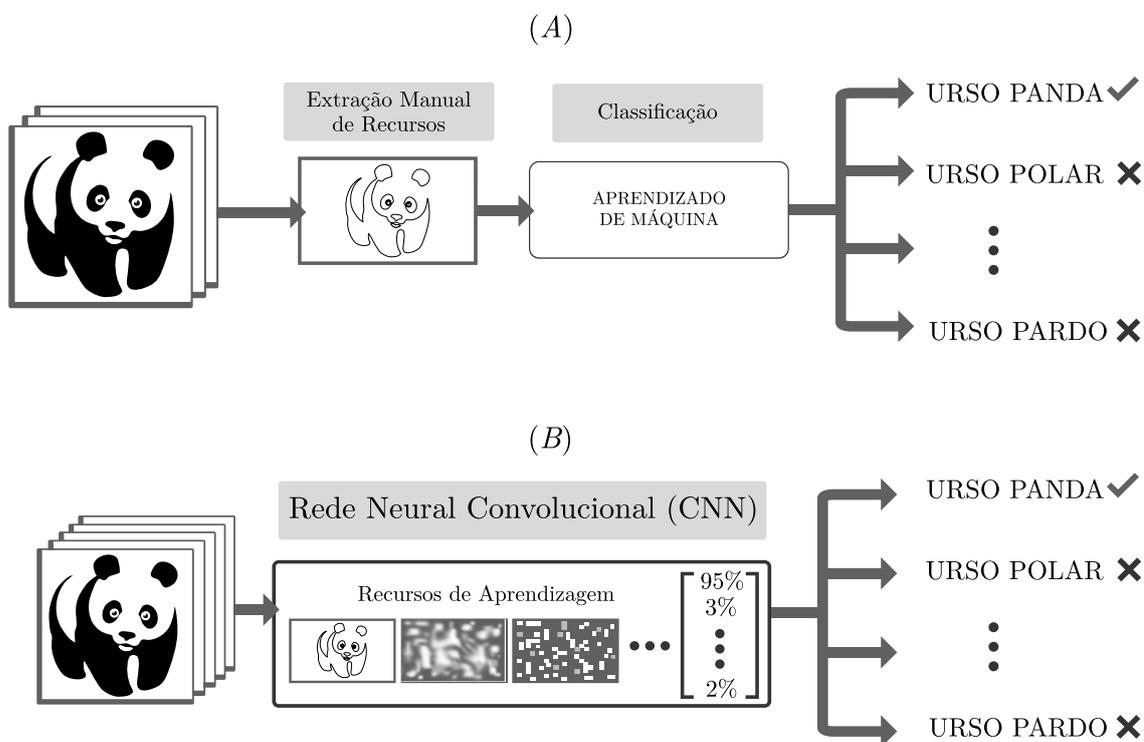
Figura 23 – Diagrama com comandos e códigos para treinamento das CNN pelo *Deep Learning Toolbox* do MATLAB.



Fonte: Elaboração do próprio autor.

Na Figura 24 é possível visualizar a comparação entre a arquitetura de uma ML (A) e a arquitetura de uma DP (B), demonstrando assim a capacidade das CNN de não utilizar a extração manual de recursos.

Figura 24 – Comparação por diagramas para *Machine Learning* e *Deep Learning*.



Fonte: Elaboração do próprio autor.

As CNNs aprendem com a detecção de diferentes características de uma imagem utilizando uma gama de camadas ocultas, onde cada camada oculta aumenta a complexidade dos recursos de imagem que foram aprendidos. A primeira camada oculta pode aprender como detectar bordas e a última pode aprender como detectar formas mais complexas especificamente relacionadas à forma do objeto ou dado que esta sendo reconhecida.

Deve-se considerar a DP como uma forma especializada de ML e um fluxo de trabalho de ML começa com recursos fundamentais sendo extraídos manualmente das imagens. Os recursos são então utilizados para criação de um modelo que categoriza os dados na imagem. Com um fluxo de trabalho da DP, os recursos fundamentais são extraídos automaticamente das imagens. Portanto, a DP realiza um aprendizado completo onde a rede captura os dados brutos e uma tarefa a ser realizada, como a própria classificação, tornando automático o aprendizado.

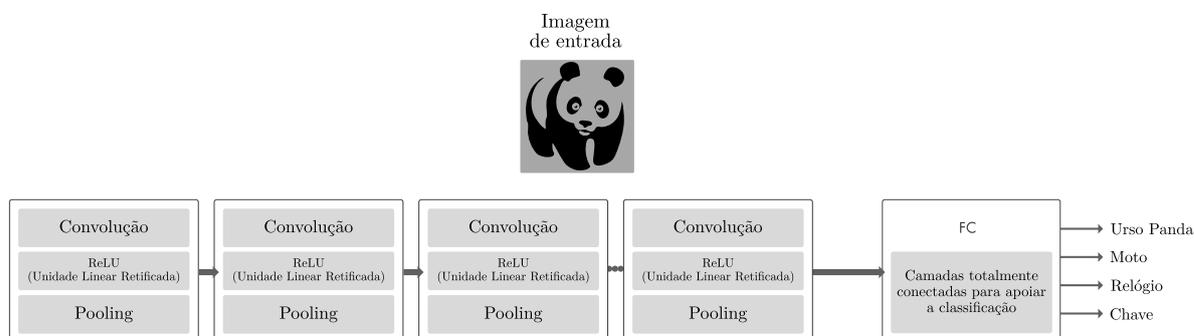
Nas escalas dos algoritmos das DPs com dados o aprendizado superficial sempre converge. O aprendizado superficial são os métodos de ML que atingem um determinado

nível de desempenho quando adicionado exemplos e dados de treinamento à uma rede. A principal vantagem das redes DP é que, muitas vezes, elas continuam a melhorar à medida que o tamanho dos dados aumentam.

O ML oferece uma variedade de técnicas e modelos que podem ser escolhidos com base na aplicação e no tamanho dos dados a serem analisados. Um aplicativo de DP eficiente requer uma grande quantidade de dados para treinar o modelo, por isso a utilização de GPUs e unidades avançadas de processamento gráfico, são necessário para processar rapidamente seus dados como apresentado na figura anterior.

A importância da escolha entre ML e DP está diretamente relacionada a estrutura computacional disponível para implementação e por isso foi considerada a utilização de GPUs de alto desempenho para rotulação dos dados adquiridos. Portanto a utilização de servidores e sistemas de alto desempenho das instalações do TNELab proporcionaram a utilização de DPs. A DP é geralmente mais complexa, demandando alto armazenamento de dados a serem adquiridos, isso resulta na obtenção de resultados confiáveis. Na Figura 25 são apresentados diagramas para exemplificar as camadas de treinamento das DPs.

Figura 25 – Diagramas com camadas de treinamento de uma DP.



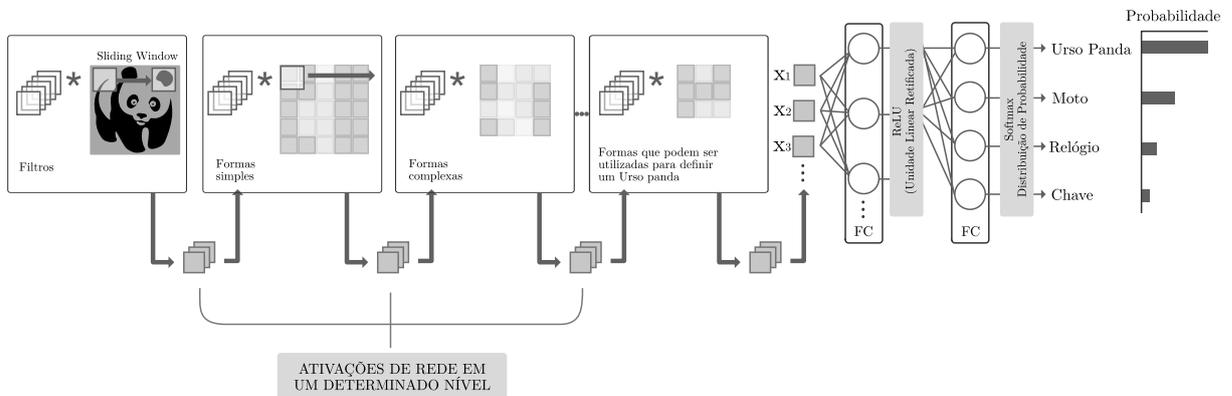
Fonte: Elaboração do próprio autor.

Existem três métodos mais comuns para o treinamento de DPs, sendo eles: o treinamento do zero, o TL e a extração de características todas essas técnicas são aplicadas para realizar as classificações de DPs. Para treinar uma DP do zero, deve-se reunir um grande conjunto de dados rotulados e projetar uma arquitetura de rede que aprenderá os recursos e o modelo. O TL, sendo um processo que envolve o ajuste fino de um modelo pré-treinado, pode iniciar com um modelo já existente, como AlexNet ou a própria GoogLeNet, que insere novos dados contendo classes anteriormente desconhecidas.

O extrator de recursos faz com que todas as camadas tenham tarefas de aprendizado com recursos certos das imagens, podemos retirar esses recursos da rede a qualquer momento

durante o processo de treinamento. Esses recursos podem ser utilizados como entrada para um modelo de ML, como por exemplo para SVMs. Na Figura 26 são apresentados diagramas para exemplificar o processo durante o treinamento das DPs.

Figura 26 – Exemplo dos processos de treinamento de uma CNN.



Fonte: Elaboração do próprio autor.

A Figura 27 apresenta as linhas de comandos utilizados no ambiente do MATLAB para realização das seleções das classes utilizando *DAGNetwork* e *SeriesNetwork*.

Figura 27 – Linhas de comando do ambiente MATLAB para iniciar as classes *DAGNetwork* e *SeriesNetwork*.

```
>> net = googlenet

net =

  DAGNetwork with properties:

      Layers: [144x1 nnet.cnn.layer.Layer]
  Connections: [170x2 table]

>> net = vgg19

net =

  SeriesNetwork with properties:

      Layers: [47x1 nnet.cnn.layer.Layer]
```

Fonte: Elaboração do próprio autor.

3.4.1 Arquitetura do Modelo CNN GoogLeNet

Para analisar e implementar as atuais aplicações do modelo de CNN GoogLeNet é importante compreender sua origem. A *Inception Network* foi um dos maiores avanços nas áreas de Redes Neurais, sendo considerada fundamental para o avanço das CNNs. São identificados na literatura três versões da *Inception Networks*, onde são chamadas de *Inception Version 1, 2 e 3*. A primeira versão foi implementada em 2014 com o nome GoogLeNet justamente por ter sido desenvolvida por pesquisadores do *Google* (SZEGEDY *et al.*, 2015).

Quando uma RNA é implementada com muitas camadas profundas, ela pode apresentar *overfitting* e com o intuito de solucionar este problema, os autores Szegedy *et al.* (2015) propuseram a arquitetura GoogLeNet idealizando a aplicação de filtros tamanhos diversos que pudessem operar no mesmo nível. Considerando a aplicação, a rede realmente se torna mais ampla, em vez de mais profunda.

A operação de convolução é realizada em entradas com três tamanhos de filtros, sendo eles com dimensionalidades 1x1, 3x3 e 5x5. Uma operação com *max-pooling* também é executada com as convoluções e posteriormente direcionado ao próximo módulo. Uma vez que as RNA aprestam alto custo, tempo de processamento elevado e a necessidade de estruturas e tecnologia avançadas, os autores limitam o número de canais de entrada adicionando uma convolução extra 1x1 antes das convoluções 3x3 e 5x5 e. dessa forma, reduzem as dimensões da rede resultando em cálculos mais rápidos.

A arquitetura GoogLeNet possui 22 camadas profundas, com 27 camadas *pool* inclusas. Contendo 9 módulos iniciais linearmente empilhados. As extremidades dos módulos são conectadas à camada de *pool* com média global. O GoogLeNet é treinado usando sistemas de aprendizado de máquina distribuídos com uma quantidade modesta de paralelismo de modelo e dados.

Dessa forma é possível relizar os treinamentos com uma descida gradiente estocástica assíncrona com um *momentum* de 0,9 e um cronograma de taxa de aprendizagem fixa, diminuindo a taxa de aprendizagem em 4% em cada 8 época. As épocas são termos utilizados no aprendizado de máquina que indicam o número de passagens de todo o conjunto de dados de treinamento que o algoritmo de aprendizado de máquina concluiu.

O GoogLeNet é treinado com diversos métodos de amostragem de *imagepatch*, foram utilizados entre 3 a 8 modelos para esta investigação, todas as convoluções, incluindo

aquelas dentro dos módulos, utilizando ativação linear retificada. O tamanho do campo receptivo implementado foi dimensionado com 224x224 com cor RGB e espaço com média zero. Essas entradas foram adquiridas pelos recursos DWT e CWT.

3.4.2 Arquitetura do Modelo CNN VGG19

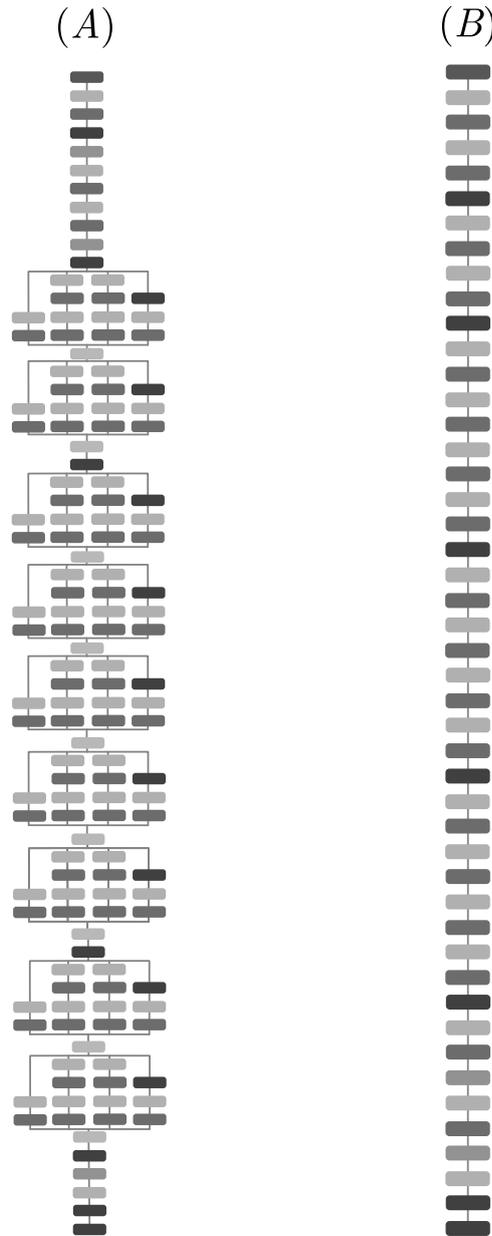
O significado de VGG se refere ao Grupo de Geometria Visual ou então *Deep Learning Visual Geometry Group* de 19 camadas o VGG19 desenvolvida por pesquisadores da Universidade de Oxford (SIMONYAN; ZISSERMAN, 2014). A VGG19 é uma arquitetura padrão CNN de aprendizado profundo com múltiplas camadas.

O profundo se refere ao número de camadas que a VGG19 consistindo de 19 camadas convolucionais. A arquitetura VGG é a base dos modelos de reconhecimento de objetos inovadores. Desenvolvido como DP, o VGGNet também supera as linhas de base em muitas tarefas e conjuntos de dados além do ImageNet. se tornando uma das arquiteturas de reconhecimento de imagem mais populares.

O modelo VGG19 é um modelo proposto por Simonyan e Zisserman (2014) e se considerando modelo anterior o VGG16 atinge quase 92,7% de precisão de teste entre os 5 primeiros no ImageNet. O ImageNet é um conjunto de dados que consiste em mais de 14 milhões de imagens pertencentes a quase 1000 classes. Além disso, foi um dos modelos mais populares submetidos no campeonato *Large Scale Visual Recognition Challenge* (ILSVRC2014). Ele substitui os filtros grandes do tamanho do *kernel* por vários filtros 3x3 em relação ao anterior, um por vez, fazendo melhorias significativas em relação ao AlexNet, um dos modelos que inspiram a VGG19 e a GoogLeNet.

O modelo VGG19 também apresenta entrada de imagem de 224 por 224. Dessa forma, o banco de dados implementado descrito anteriormente pode ser utilizado na alimentação de entrada dos dois modelos propostos. Os modelo VGG19 apresenta uma estrutura de 47 *layers* e o modelo GoogLeNet apresenta uma estrutura com 144 *layers*. A Figura 28 apresenta o ambiente do MATLAB com as estruturas e arquiteturas dos dois modelos implementados, sendo (A) a arquitetura da CNN GoogLeNet com 144 camadas e (B) a arquitetura da CNN VGG19 com 47 camadas. Essas arquiteturas como apresentadas são blocos dinâmicos extraídos da *Toolbox Deep Learning* do MATLAB.

Figura 28 – Arquitetura em blocos das camadas das CNN GoogleNet e VGG19.



Fonte: Elaboração do próprio autor.

3.5 PERFORMANCE: TESTES E MÉTRICAS

A eficiência em um processo de aprendizagem é mensurada pela capacidade de classificar dados desconhecidos em relação a treinamentos realizados com dados conhecidos. Em classificações binárias supervisionadas, conceito amplamente discutido nesta tese, para mensuração das capacidades de classificação normalmente são utilizadas as medidas de acurácia, definida como o número de acertos em relação ao total de elementos que serão classificados (FORERO, 2019).

No entanto, quando existem classes desequilibradas utilizar a acurácia como única fonte de mensuração pode gerar dados equivocados. Podemos citar, como exemplo, a aplicação de um algoritmo para classificar 100 dados, onde 80% pertence a uma classe A e 20% pertence a uma classe B. Se a execução o algoritmo classificar todos os 100 dados dentro da classe A, teríamos uma acurácia geral de 80%, mesmo que o classificador ficasse sem realizar nenhuma função.

Quando existem bases de dados desequilibradas devemos considerar a utilização de outros fatores de mensuração como os presentes nas matrizes de confusão, uma tabela para apresentação de diferenças e comportamentos do algoritmo implementado na conclusão da classificação correta ou incorreta dos dados apresentados (BRADLEY, 1997).

Na Figura 29 está sendo apresentada uma matriz de confusão de um classificador binário para um *testing set* desequilibrado de 100 dados, onde 60% correspondem à classe A, sendo considerada a classe negativa e 40% dos dados são correspondentes à classe B, sendo considerada a classe positiva.

Figura 29 – Exemplo de uma matriz de confusão binária.

		Saída Desejada		
		0	1	
Saída Classificador	0	50	5	0 = Classe A 1 = Classe B
	1	10	35	
		60	40	

Fonte: Adaptado de Forero (2019).

Em uma matriz de confusão os dados são classificados são etiquetados de acordo com a sua validade, ou seja, corretos e incorretos classificados são etiquetados como: verdadeiro positivo (VP) e verdadeiro negativo (VN), falso positivo (FP) e falso negativo (FN). Sendo VP o dado da classes positiva corretamente classificado e o VN são os dados da classe negativa corretamente classificados, o FP são os dados positivos incorretamente classificados e o FN são os dados negativos incorretamente classificados.

Para a precisão são considerados os dados das matrizes de confusão é possível estabelecer os seguintes parâmetros que permitem avaliar a eficiência do processo de aprendizado profundo: acurácia (ACC), sensibilidade (SE), Especificidade (ESP), Seletividade (SEL) e *F1 Score* (F1).

$$\text{ACC} = \frac{VP + VN}{VP + VN + FP + FN} \cdot 100\% \quad (52)$$

$$\text{SE} = \frac{VN}{VN + FP} \cdot 100\% \quad (53)$$

$$\text{ESP} = \frac{VN}{VN + FP} \cdot 100\% \quad (54)$$

$$\text{SEL} = \frac{VP}{VP + FP} \cdot 100\% \quad (55)$$

$$F_1 = 2 \cdot \frac{\text{precisão} \cdot \text{recall}}{\text{precisão} + \text{recall}} = \frac{2VP}{2VP + FP + FN} \quad (56)$$

Sendo SE a capacidade do algoritmo de classificar corretamente dados da classe positiva. A ESP mede a capacidade do algoritmo em classificar dados dentro da classe negativa. A SEL quantifica a capacidade do classificador para rejeitar falsas detecções da classe positiva, a ACC como citado anteriormente mede a eficiência do algoritmo ao classificar corretamente os diferentes dados e F1 consiste na análise da precisão e da revocação ou *recall* do teste (GOUTTE; GAUSSIER, 2005; YACOUBY; AXMAN, 2020).

Sendo a precisão são considerados os números com resultados verdadeiros positivos e o *recall* são os números dos resultados verdadeiros positivos dividido pelo número de todas as amostras que deveriam ter sido identificadas como positivas (BEGG; KAMRUZZAMAN, 2006). A Figura 30 apresenta um diagrama de forma organizada e exemplifica as aplicações de métricas para validações clínicas e de diagnóstico (MORSTATTER *et al.*, 2016).

Figura 30 – Diagrama representado as estruturas dos testes e métricas.

		Doença		Valor Preditivo	
		⊕	⊖		
Teste	⊕	A Verdadeiro Positivo (VP)	B Falso Positivo (FP)	Valor Preditivo Positivo (VPP) $\frac{TP}{TP + FP} = \frac{A}{A + B}$	Resultados Positivos Totais (A + B)
	⊖	C Falso Negativo (FN)	D Verdadeiro Negativo (VN)	Valor Preditivo Negativo (VPN) $\frac{TN}{FN + TN} = \frac{D}{C + D}$	Resultados Negativos Totais (C + D)
Sensitividade e Especificidade		Sensitividade $\frac{TP}{TP + FN} = \frac{A}{A + C}$	Especificidade $\frac{TN}{FP + TN} = \frac{D}{B + D}$		
		Todos os pacientes doentes (A + C)	Todos os pacientes saudáveis (B + D)		

Fonte: Elaboração do próprio autor.

4 RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados os resultados obtidos na implementação da interface neural HDsEMG, os resultados obtidos com o processamento dos sinais eletromiográficos e os resultados obtidos com a utilização do conceito de *Transfer Learning* para classificação com os modelos CNN GoogLeNet e VGG19 propostos.

Após o processamento do banco de dados capturados pela interface neural HDsEMG, foi realizada a comparação das classificações entre os modelos DL o GoogLeNet e o VGG19, também foi implementado um *dataset*. Contendo as informações neurais de todos os voluntários e suas respectivas classes (*labels*) originadas pelos movimentos definidos no protocolo experimental.

Os resultados para os modelos DL são divididos aos pares apresentando as classes em quatro grupos, mais a classe de repouso, totalizando nove classes para a classificação utilizando os modelos propostos. Para avaliação dos modelos foram utilizados os parâmetros acurácia, sensibilidade, especificidade e seletividade e *F1 Score* descritos no Capítulo 3.

4.1 HDSEMG PROCESSADO

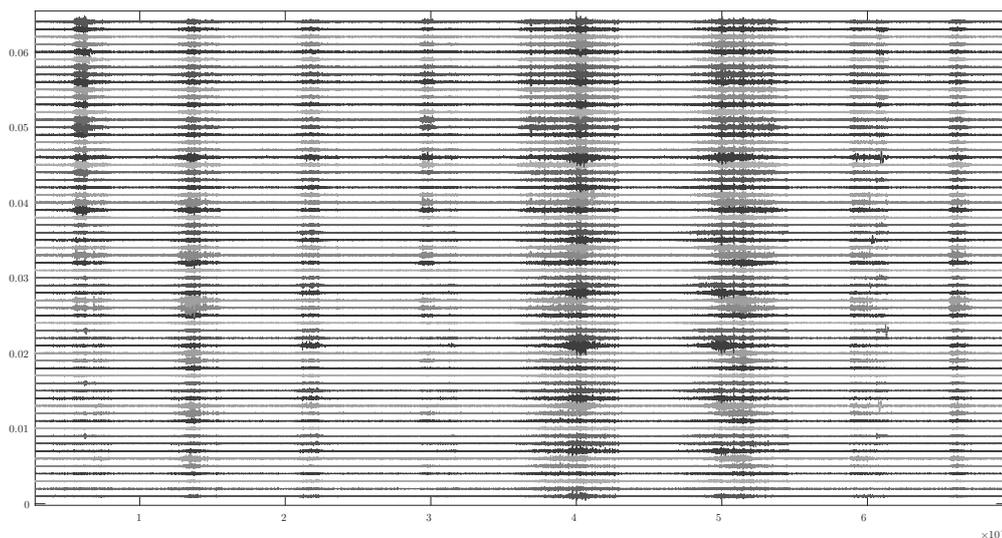
Com a implantação da interface neural HDsEMG foram coletados um número significativo de dados, constituídos de diversos movimentos definidos pelo protocolo experimental para tarefas a serem realizadas pelos voluntários presentes nesta investigação. O HDsEMG bruto, ou seja sem a extração de recursos e filtros no pré-processamento. Foram então submetidos à uma série de processos para extração de características e reconhecimento de padrões descritos no Capítulo 2.

A Figura 31 consiste no HDsEMG já pré-processado e classificado, a abordagem de apresentar primeiro o resultado de conclusão do processamento foi necessária para a compreensão do banco de dados, que foi gerado para a alimentação dos modelos nas classificações, onde são apresentados 64 canais defasados uns dos outros no eixo *Y* para facilitar a visualização dos momentos de atividade das MUs nos movimentos definidos, diferente dos sinais apresentados com repetições anteriormente, na figura eles estão reorganizados e concatenados com uma amostra por movimento.

Pode-se observar as interações musculares mais os momentos de repouso, sendo elas as nove classes para as classificações. Elas estão dispostas na seguinte ordem MFP, MHP,

MDR, MDU, MCH, MCA, MFI e MFM. Os dados HDsMG já filtrados, são processados etiquetados de acordo com cada extração, essa etiquetação foi descrita anteriormente como *labelling*, ou seja, um algoritmo que cria etiquetas, também denominadas classes, para cada um dos movimentos e posteriormente, reagrupam de forma que os modelos de classificação supervisionada possam identificar cada uma de forma independente e precisa.

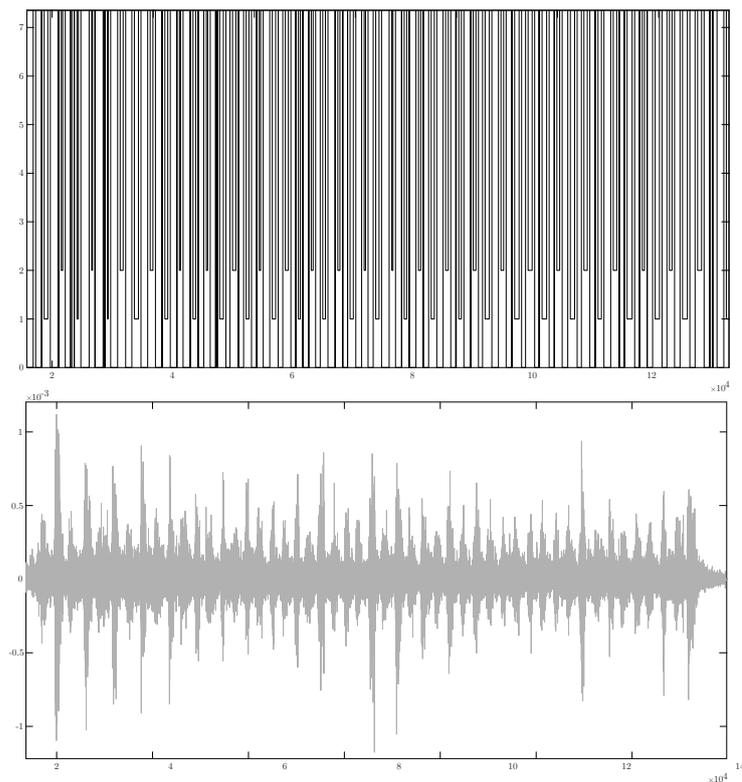
Figura 31 – Gráfico com 64 sinais HDsEMG processados e reorganizados.



Fonte: Elaboração do próprio autor.

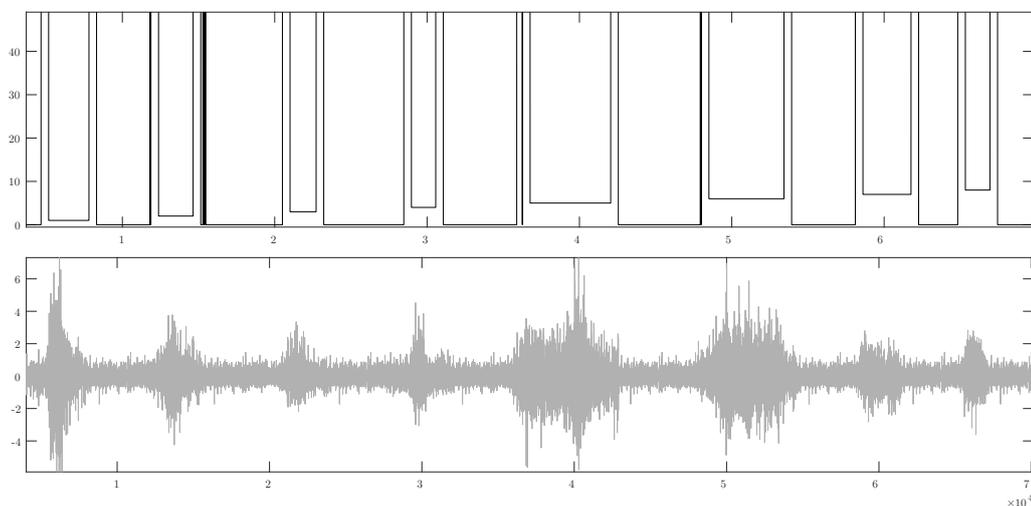
Para organização de todos os HDsEMG foi implementado um algoritmo para extração dessas *labels* para identificação de padrões nos sinais adquiridos. A Figura 32 apresenta o processo de *labelling* no banco de dados, na figura está apresentando os dados de um dos voluntários.

Essa ação possibilitou organizar de forma prática todos os dados adquiridos dos voluntários. Pelo entendimento do grupo de pesquisa, seguindo a literatura, armazenar repetições era a forma mais adequada de criar uma quantidade significativa de amostras para os classificadores. Essa ação foi repetida em todos os dados coletados e cada repetição apresenta características distintas, uma vez que cada movimento, por mais que realizem a mesma ação, possui parâmetros diferentes, como fadiga, tremores, alteração de velocidade e limites de posição.

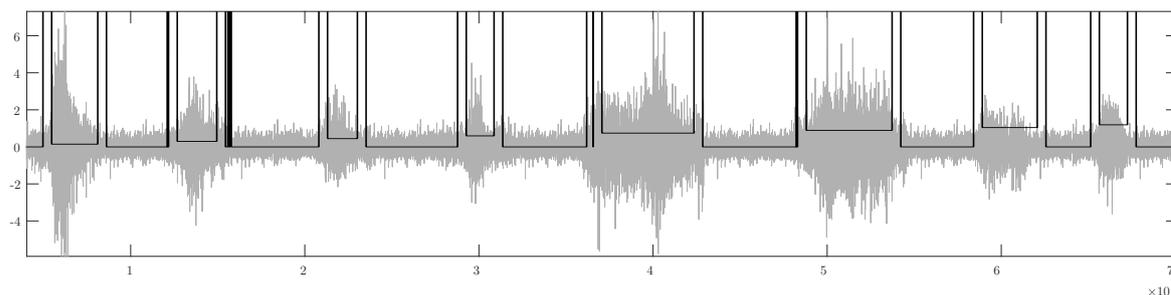
Figura 32 – Plotagem do algoritmo de extração de *labels*.

Fonte: Elaboração do próprio autor.

Nas Figura 32, 33 e 34 são apresentadas as extrações *labels* nos sinais processados e cada vez que o algoritmo de extração identifica uma contração, automaticamente ele incrementa uma nova hierárquica para rotulação das *labels*. As classes então passam a ter nomes ou sequenciamento numéricos, isto é determinado pela configuração no *script* da programação proposta.

Figura 33 – Gráfico de extração de *labels* dos sinais HDsEMG.

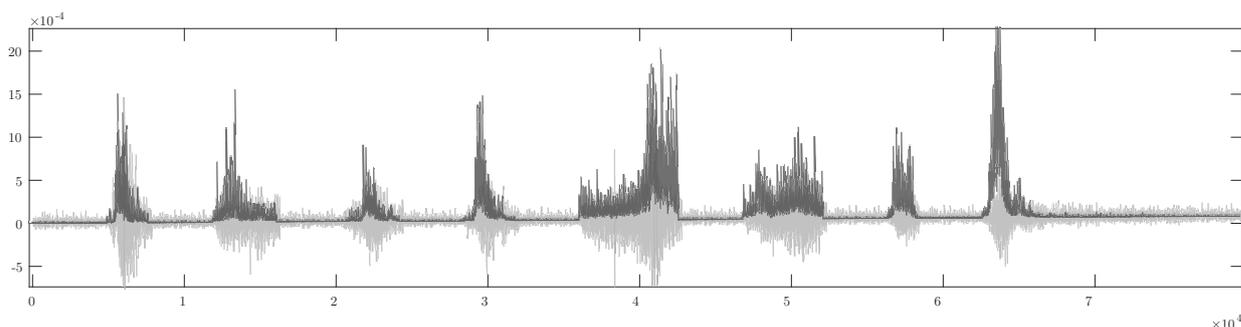
Fonte: Elaboração do próprio autor.

Figura 34 – Gráfico de sobreposição da extração de *labels* do HDsEMG

Fonte: Elaboração do próprio autor.

A Figura 35 apresenta de forma concisa a formalização dos métodos de extração de recursos e reconhecimento, onde o sinal eletromiográfico é mapeado ponto a ponto por diversos recursos e processado pela implementação de um algoritmo automático para extração de classes do sinal, o *labelling* como descrito no Capítulo 2.

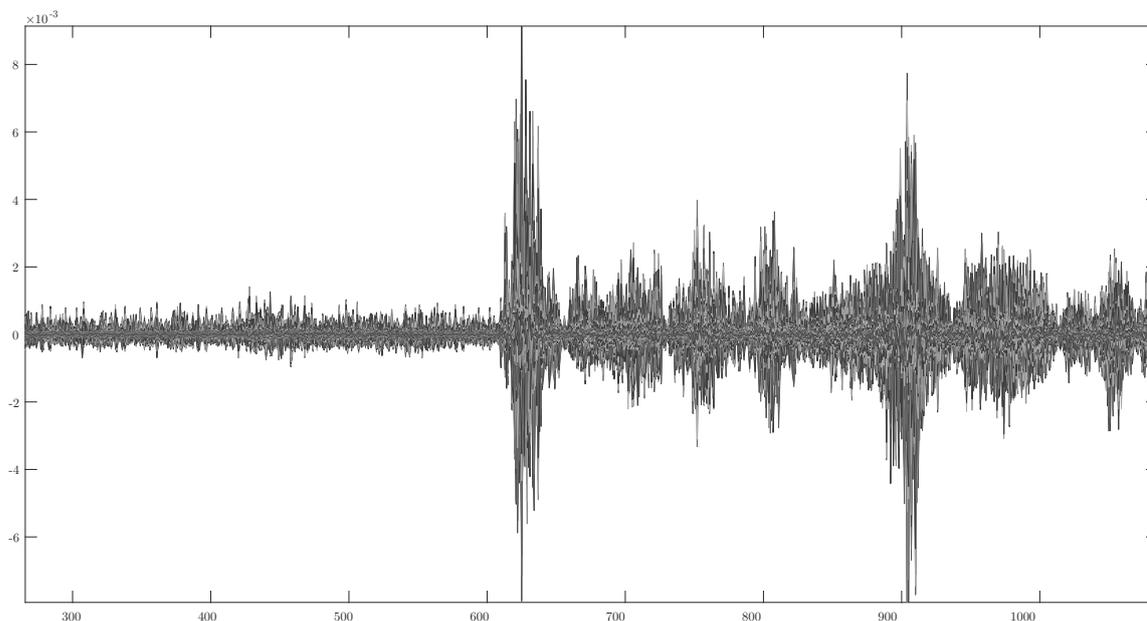
Figura 35 – Gráfico de extração de características do HDsEMG



Fonte: Elaboração do próprio autor.

Com o sinal categorizado e organizado para geração de amostras em imagens, parte fundamental para os classificadores CNN e aplicando as técnicas dos PCAs, foram investigadas as quantidades de principais componentes (PCs) no banco de dados que justifiquem mais 85% de todo o sinal, caso contrário se o número de PCs for insuficiente os classificadores ficarão prejudicados. Considerando esta percentagem foram definidos a extração de nove PCs do conjunto total de dados.

Neste sentido, o PCA aplicado nos dados reconhecem os canais HDsEMG com maiores e melhores informações dadas ao classificador pela seleção dos PCs. Como mostrado na Figura 36, os nove PCs processados e extraídos e mais as características são disponibilizados por ordem durante a seleção dos sinais. Observava-se que os movimentos de repouso agora estão organizados na frente do sinal e foram reconhecidos entre as classes etiquetadas.

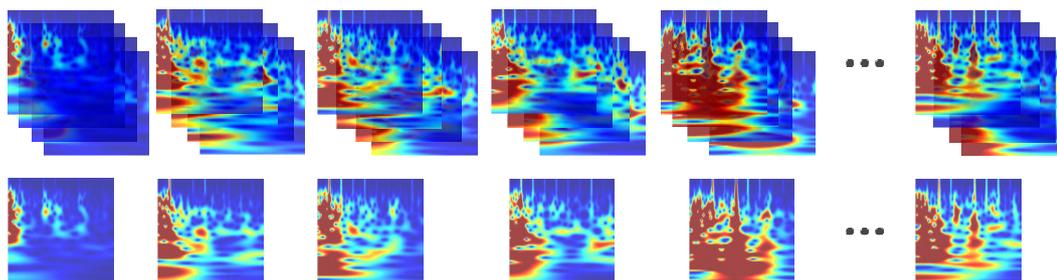
Figura 36 – Gráfico com classificadores PCA reorganizado por *labels*

Fonte: Elaboração do próprio autor.

Em seguida foram implementadas as Transformadas de *Wavelets* Contínuas e Discretas, responsáveis pela geração de amostras que alimentarão o treinamento durante a classificação. Neste processo quando o algoritmo das transformadas realizam as conversões de biosinais em escalogramas são aplicados métodos de *overlapping*, sobreposições ao longo do tempo para mapear e amostrar todos os instantes desejados dos sEMG no tempo como descrito no Capítulo 2 .

Essas técnicas variam de acordo com a porcentagem definida no janelamento pretendido. Por exemplo as amostras podem conter o deslocamento da janela deslizante WL em 10%, 20%, 30%, 50%, 80% de todo o sinal e nesta tese o WL foi implementado de 10% a 20%. Na Figura 37 são apresentados exemplos de imagens de escalogramas criados neste processamento. As interações dos classificadores podem processar milhões destas imagens simultaneamente. Como descrito anteriormente, as análises com escalogramas ocorrem pelas informações dos padrões RGB e, por isso, a Figura 37 deve ser apresentada com cores.

Figura 37 – Exemplos dos escalogramas criados para as classes dos treinamentos.



Fonte: Elaboração do próprio autor.

4.2 RESULTADOS REDES NEURAI CONVOLUCIONAIS

4.2.1 Matrizes de confusão e métricas para CNN GoogLeNet

O treinamento da CNN GoogLeNet foi realizado com dados de todos os voluntários presentes. A Figura 38 apresenta a matriz de confusão onde podemos verificar que a melhor classificação foi para a classe dos movimentos MFP, onde 55 amostras foram classificadas corretamente. As classes dos movimentos MHP e RPO apresentaram classificação em 8 e 12 amostras respectivamente.

Figura 38 – Matriz de Confusão do modelo CNN GoogLeNet para as classes de movimentos MFP e MHP.

Classes Reais	MFP	55 55.0%	5 5.0%	7 7.0%	82.1% 17.9%
	MHP	3 3.0%	8 8.0%	3 3.0%	57.1% 42.9%
	RPO	5 5.0%	2 2.0%	12 12.0%	63.2% 36.8%
		87.3% 12.7%	53.3% 46.7%	54.5% 45.5%	75.0% 25.0%
	MFP	MHP	RPO	Classes Preditas	

Fonte: Elaboração do próprio autor.

Na Tabela 7 as classes dos movimentos MFP e MHP apresentaram uma acurácia de 75,00%. A tabela também apresenta os valores de parâmetros das métricas que auxiliam na avaliação da eficiência deste aprendizado. Sendo eles, a sensibilidade, especificidade, seletividade e *F1 Score*.

Tabela 7 – Valores das funções de treinamento do modelo CNN GoogLeNet para as classes de movimentos MFP e MHP.

Variável	Valor
Acurácia (%)	75,00
Sensibilidade (%)	65,06
Especificidade (%)	83,84
Seletividade (%)	67,46
<i>F1 Score</i> (%)	66,11

Fonte: Elaboração do próprio autor.

Na matriz de confusão apresentada pela Figura 39 podemos observar que a pior classificação ficou para os movimentos MDU com apenas 15 amostras classificadas corretamente. Na condição de inércia dos voluntários, o repouso recebeu a melhor classificação, sendo 157 amostras classificadas corretamente.

Figura 39 – Matriz de Confusão do modelo CNN GoogLeNet para as classes de movimentos MDR e MDU.

Classes Reais	MDR	33 12.8%	15 5.8%	10 3.9%	56.9% 43.1%
	MDU	8 3.1%	15 5.8%	7 2.7%	50.0% 50.0%
	RPO	9 3.5%	4 1.6%	157 60.9%	92.4% 7.6%
		66.0% 34.0%	44.1% 55.9%	90.2% 9.8%	79.5% 20.5%
		MDR	MDU	RPO	Classes Preditas

Fonte: Elaboração do próprio autor.

Na Tabela 8 são apresentados os valores dos parâmetros de validação. Para este treinamento os movimentos MDR e MHP obtiveram uma acurácia de 79,50%. Também são apresentados os valores de sensibilidade, especificidade, seletividade e *F1 Score*.

Tabela 8 – Valores das funções de treinamento do modelo CNN GoogLeNet para as classes de movimentos MDR e MHP.

Variável	Valor
Acurácia (%)	79,50
Sensibilidade (%)	66,78
Especificidade (%)	88,60
Seletividade (%)	66,42
<i>F1 Score</i> (%)	66,42

Fonte: Elaboração do próprio autor.

Podemos observar na Figura 40 que os movimentos MCH e RPO receberam a melhor classificação do treinamento sendo 112 e 151 amostras classificadas corretamente pela CNN GoogLeNet. O movimento MCA apresenta 58 amostras, ou seja 13% das classes classificadas corretamente.

Figura 40 – Matriz de Confusão do modelo CNN GoogLeNet para as classes de movimentos MCH e MCA.

Classes Reais	MCA	58 13.0%	24 5.4%	4 0.9%	67.4% 32.6%
	MCH	66 14.8%	112 25.1%	19 4.3%	56.9% 43.1%
	RPO	7 1.6%	6 1.3%	151 33.8%	92.1% 7.9%
		44.3% 55.7%	78.9% 21.1%	86.8% 13.2%	71.8% 28.2%
	MCA	MCH	RPO	Classes Preditas	

Fonte: Elaboração do próprio autor.

Na Tabela 9 são apresentados os valores de classificação para os movimentos MCH e MCA onde os mesmos obtiveram uma acuraria de 71,83%. Os parâmetros auxiliares para validade desta avaliação também são apresentados. Os valores de validação são: sensibilidade, especificidade, seletividade e *F1 Score* para a classificação dos movimentos MCH e MCA.

Tabela 9 – Valores das funções de treinamento do modelo CNN GoogLeNet para as classes de movimentos MCH e MCA.

Variável	Valor
Acurácia (%)	71,83
Sensibilidade (%)	70,49
Especificidade (%)	86,39
Seletividade (%)	72,56
<i>F1 Score</i> (%)	70,20

Fonte: Elaboração do próprio autor.

E para concluir as classificações utilizando a CNN GoogLeNet, a Figura 41 apresenta que os movimentos MFI e MFM classificaram 21 e 28 amostras corretamente, mais uma vez o repouso recebe a melhor classificação.

Figura 41 – Matriz de Confusão do modelo CNN GoogLeNet para as classes de movimentos MFI e MFM.

Classes Reais	MFI	21 14.7%	14 9.8%	6 4.2%	51.2% 48.8%
	MFM	10 7.0%	28 19.6%	5 3.5%	65.1% 34.9%
	RPO	6 4.2%	1 0.7%	52 36.4%	88.1% 11.9%
		56.8% 43.2%	65.1% 34.9%	82.5% 17.5%	70.6% 29.4%
		MFI	MFM	RPO	Classes Preditas

Fonte: Elaboração do próprio autor.

Conforme apresenta a Tabela 10, a acurácia obtida foi de 70,63% para as classes de movimento MFI e MFM.

Tabela 10 – Valores das funções de treinamento do modelo CNN GoogLeNet para as classes de movimentos MFI e MFM.

Variável	Valor
Acurácia (%)	70,63
Sensibilidade (%)	68,14
Especificidade (%)	85,79
Seletividade (%)	68,16
<i>F1 Score</i> (%)	68,07

Fonte: Elaboração do próprio autor.

4.2.2 Matrizes de confusão e métricas para CNN VGG19

O treinamento da CNN VGG19 também foi realizado com dados de todos os voluntários. Na Figura 42 mostra que as duas melhores classificações são dos movimentos MFP e RPO com 40 e 50 amostras classificadas corretamente.

Figura 42 – Matriz de Confusão do modelo CNN VGG19 para as classes de movimentos MFP e MHP.

Classes Reais	MFP	40 23.1%	21 12.4%	1 0.6%	63.9% 36.1%
	MHP	10 5.9%	29 17.1%	3 1.8%	68.3% 31.7%
	RPO	2 1.2%	6 3.6%	59 34.9%	88.1% 11.9%
		76.5% 23.5%	50.9% 49.1%	93.7% 6.3%	75.7% 25.4%
	MFP	MHP	RPO	Classes Preditas	

Fonte: Elaboração do próprio autor.

Na Tabela 11 os movimentos MFP e MHP obtiveram uma acurária de 75,74%. Este resultado também é avaliado pelos parâmetros de validação, sensibilidade, especificidade, seletividade e *F1 Score*.

Tabela 11 – Valores das funções de treinamento do modelo CNN VGG19 para as classes de movimentos MFP e MHP.

Variável	Valor
Acurácia (%)	75,74
Sensibilidade (%)	74,94
Especificidade (%)	88,04
Seletividade (%)	74,79
F1 Score (%)	74,20

Fonte: Elaboração do próprio autor.

Na Figura 43 observa-se que a matriz de confusão, com os dados de todos os voluntários, apresentou 172 amostras classificadas corretamente e a pior classificação apresentou 15 amostras classificadas corretamente. a precisão mostra que 75,00% das amostras foram validas no treinamento.

Figura 43 – Matriz de Confusão do modelo CNN VGG19 para as classes de movimentos MDR e MDU.

Classes Reais	MDR	34 13.2%	13 5.0%	1 0.4%	70.8% 29.2%
	MDU	4 1.6%	15 5.8%	1 0.4%	75.0% 25.0%
	RPO	12 4.7%	6 2.3%	172 66.7%	90.5% 9.5%
		68.0% 32.0%	44.1% 55.9%	98.9% 1.1%	85.7% 14.3%
		MDR	MDU	RPO	
		Classes Preditas			

Fonte: Elaboração do próprio autor.

A Tabela 12 os movimentos MDR e MDU obtiveram uma acurácia de 85,66% e especificidade de 89,32%, parâmetros adicionais foram implementados para garantir sua validade. Podemos observar que existe uma melhora na classificação utilizando a CNN VGG19, quando comparado aos resultados anteriores.

Tabela 12 – Valores das funções de treinamento do modelo CNN VGG19 para as classes de movimentos MDR e MDU.

Variável	Valor
Acurácia (%)	85,66
Sensibilidade (%)	70,32
Especificidade (%)	89,87
Seletividade (%)	78,79
F1 Score (%)	73,15

Fonte: Elaboração do próprio autor.

A matriz de confusão apresentada na Figura 44 mostra que o pior classificação tem 80 amostras classificadas corretamente e os movimentos MCH e RPO apresentam 101 e 165 amostras classificadas corretamente. Neste treinamento as classes dos movimentos MCH e MCA obtiveram uma acurácia de 77,40%.

Figura 44 – Matriz de Confusão do modelo CNN VGG19 para as classes de movimentos MCH e MCA.

Classes Reais	MCA	80 17.9%	36 8.1%	5 1.1%	66.1% 33.9%
	MCH	44 9.8%	101 22.6%	4 0.9%	67.8% 32.2%
	RPO	7 1.6%	5 1.1%	165 36.9%	93.2% 6.8%
		61.1% 38.9%	71.1% 28.9%	94.8% 5.2%	77.4% 22.6%
	MCA	MCH	RPO	Classes Preditas	

Fonte: Elaboração do próprio autor.

Na Tabela 13 os parâmetros auxiliares são apresentados em conjunto para garantir a validação do treinamento e os parâmetros são a sensibilidade, a especificidade, a seletividade e o *F1 Score*.

Tabela 13 – Valores das funções de treinamento do modelo CNN VGG19 para as classes de movimentos MCH e MCA.

Variável	Valor
Acurácia (%)	77,40
Sensibilidade (%)	75,67
Especificidade (%)	88,96
Seletividade (%)	75,71
F1 Score (%)	75,64

Fonte: Elaboração do próprio autor.

Na Figura 45 apresenta a matriz de confusão das classificações para as classes de movimentos MFI e MFM, sendo 24 e 19 amostras classificadas corretamente.

Figura 45 – Matriz de Confusão do modelo CNN VGG19 para as classes de movimentos MFI e MFM.

Classes Reais	MFI	19 13.7%	9 6.5%	1 0.7%	65.5% 34.5%
	MFM	12 8.6%	24 17.3%	1 0.7%	64.9% 35.1%
	RPO	6 4.3%	10 7.2%	57 41.0%	78.1% 21.9%
		51.4% 48.6%	55.8% 44.2%	96.6% 3.4%	71.9% 28.1%
		MFI	MFM	RPO	Classes Preditas

Fonte: Elaboração do próprio autor.

Na Tabela 14 são apresentados parâmetros de validação do treinamento, sendo que os movimentos MFI e MFM apresentam uma acurácia de 73,83%. Os resultados obtidos apresentam uma diferença ente os modelos de classificação e é possível observar

que o modelo CNN VGG19 apresenta métricas mais elevadas se comparadas aos modelos GoogLeNet. Se considerarmos as demais métricas podemos classificar em qual o modelo se enquadra melhor a cada conjunto de classes.

Tabela 14 – Valores das funções de treinamento do modelo CNN VGG19 para as classes de movimentos MFI e MFM.

Variável	Valor
Acurácia (%)	71,94
Sensibilidade (%)	67,93
Especificidade (%)	85,55
Seletividade (%)	66,87
F1 Score (%)	67,98

Fonte: Elaboração do próprio autor.

Esta discussão apresenta os parâmetros utilizados na arquitetura das classificações, apresentando 20.000 imagens de escalogramas disponíveis para construção do banco de dados implementado. Anteriormente ao último treinamento dos modelos eram calculados aproximadamente 60.000 imagens de escalogramas. No entanto, este número foi reduzido quando os parâmetros de WL foram permanentemente definidos. O tempo de treinamento e processamento dos modelos variam de acordo com o banco de dados implementado, outro fator fundamental para esta definição são os parâmetros das camadas. As camadas capturam imagens maiores e as reduzem e também reduzem os parâmetros para preservar a formação da imagem (KRISHNA; KALLURI, 2019; AHMED *et al.*, 2021).

A CNN GoogLeNet apresenta aproximadamente 4 milhões de parâmetros entre as camadas e a CNN VGG19 apresenta aproximadamente 143 milhões destes parâmetros. Analisando o tempo de treinamento entre o modelo GoogLeNet e VGG19 podemos verificar que a CNN GoogLeNet apresenta o melhor desempenho em relação ao tempo. Isto ocorre por que o modelo GoogLeNet foi substituído por agrupamentos médios após a última camada convolucional, ao invés de camadas totalmente conectadas no final, isto reduz significativamente o número de parâmetros (SEIBOLD *et al.*, 2017; ZHANG *et al.*, 2017).

Por outro lado, semelhantes configurações de camada das CNN demonstram que o aumento do número de camadas de convolução contribuem para o desempenho das redes quando comparadas. Outra análise a ser observada é considerar o número de FCs. O modelo GoogLeNet com aproximadamente 5% dos parâmetros do modelo VGG19

parâmetros apresentaram uma pontuação semelhante. Isso pode ser vinculado a o baixo número de características definidos entre as camadas. A Tabela 15 as comparações das métricas e dos tempos de treinamento de cada classe, sendo elas: (A) as classes MFP e MHP, (B) as classes MDR e MDU, (C) as classes MCH e MCA e (D) as classes MFI e MFM.

Tabela 15 – Comparação de classificação entre as métricas de validação das CNNs GoogLeNet e VGG19.

Métricas	CNN GoogLeNet	CNN VGG19
(A)	Tempo 24min e 71s	Tempo 276min e 17s
Acurácia (%)	75,00	75,74
Sensibilidade (%)	65,06	74,94
Especificidade (%)	83,84	88,04
Seletividade (%)	67,46	74,79
F1 Score (%)	66,11	74,20
(B)	Tempo 100min e 23s	Tempo 582min e 04s
Acurácia (%)	79,50	85,66
Sensibilidade (%)	66,78	70,32
Especificidade (%)	88,60	89,87
Seletividade (%)	66,42	78,79
F1 Score (%)	66,42	73,15
(C)	Tempo 234min e 12s	Tempo 1,336min e 17s
Acurácia (%)	71,83	77,40
Sensibilidade (%)	70,49	75,67
Especificidade (%)	86,39	88,96
Seletividade (%)	72,56	75,71
F1 Score (%)	70,20	75,64
(D)	Tempo 41min e 56s	Tempo 212min e 31s
Acurácia (%)	70,63	71,94
Sensibilidade (%)	68,14	67,93
Especificidade (%)	85,79	85,55
Seletividade (%)	68,16	66,87
F1 Score (%)	68,07	67,98

Fonte: Elaboração do próprio autor.

O tempo de treinamento e processamento estão diretamente relacionados aos parâmetros de cada modelo e se forem analisados de acordo com a aplicação de cada CNN apresentará uma vantagem específica na implementação desejada. No entanto, o custo computacional poderá ser agregado se o modelo aplicado no sistema neuroprotético for classificado apenas uma vez. Já para uma estrutura onde o aprendizado é contínuo deve-se considerar o menor custo computacional na demanda por tempo.

5 CONCLUSÕES

Esta tese apresentou um conjunto de evidências sobre a capacidade e a aplicabilidade de modelos CNN e seus potenciais na classificação de movimentos para o acionamento de neuropróteses de membros superiores. É possível verificar na literatura que nas últimas duas décadas esforços globais estão sendo aplicados para aperfeiçoar esses dispositivos. As neuropróteses transradiais utilizam o sinal eletromiográfico para o seu acionamento. As investigações em modernas técnicas de classificação no reconhecimento e aprendizagem de padrões, tais como a previsão das intenções de movimentos do usuário, colaborou significativamente para os resultados apresentados.

Nesta tese foi defendido que direcionar as interfaces neurais HDsEMG para interações com modelos atuais de *deep learning* é necessário, mas não suficiente se o banco de dados e a interface neural não acompanharem protocolos e diretrizes específicos na implementação destes sistemas.

O intercâmbio científico realizado pelo autor para o aperfeiçoamento e definição do tema desta tese foram partes integrantes dos resultados obtidos, pois permitiu assim, o aprendizado de novas técnicas e teorias no acionamento de neuropróteses em geral. A interdisciplinaridade presente nesta área do conhecimento foi um desafio explorado durante todo o desenvolvimento desta tese.

A interface neural multicanal HDsEMG com 64 canais apresentou resultados positivos na aquisição de um banco de dados. Garantindo resultado direto na performance dos classificadores, que necessitam cada vez mais de dados de entrada em seu processo de aprendizagem. A interface neural implementada tem condições de satisfazer esta demanda seja para interface de aquisição de sEMG ou para o interfaceamento de comando de dispositivos protéticos. No processamento dos sinais eletromiográficos aplicado nesta tese, foram utilizando diversos recursos para extração de características e reconhecimento de padrões, destacando-se os recursos de RMS, WL, SW, DWT e CWT e a extração de classes do sinal no domínio do tempo utilizando as técnicas de *labelling* e *overlapping* integradas.

Comparando os dois modelos de GoogLeNet e VGG19, destaca-se a eficácia da conceito de *Transfer Learning*. As classificações foram aplicadas para o treinamento de nove classes, resultantes de oito movimentos da mão e do antebraço mais a classe de repouso e esses dados foram adquiridos por um protocolo de tarefas com nove voluntários hígidos.

O processamento e o treinamento dos dados ocorreram pela junção das amostras de todos os voluntários, formalizando um conjunto de amostras para cada treinamento, o modelo GoogLeNet apresentou acurácia máxima de 79,46% e o modelo VGG19 apresentou acurácia máxima de 85,66%. Ambos os modelos receberam validação de múltiplas métricas para garantir a eficiência do aprendizado. Foram aplicadas cinco métricas de validação, sendo elas a acurácia, a sensibilidade, a especificidade, a seletividade e o *F1 Score*.

Para concluir, as investigações apresentadas nesta tese fornecem uma base sólida para implementação de classificadores de redes neurais convolucionais profundas. Sendo ambas as estratégias abordadas podem efetivamente melhorar os resultados funcionais no processo de comando e acionamento de neuropróteses transradiais.

Trabalhos Futuros

Reunindo os conceitos integrantes desta tese é possível identificar um cenário promissor para o futuro das neuropróteses transradiais. Será possível imaginar como as estratégias dos modelos de aprendizagem podem ser projetados para auxiliar no comando destas próteses, gerando resultados superiores. Apesar da estratégia de implementação dos modelos propostos nesta tese, que aborda principalmente conceitos computacionais, a implementação com mecanismos podem ser alcançadas no futuro.

Para tornar estas perspectivas válidas pode-se colaborar diretamente para o desenvolvimento de dispositivos protéticos com eletromiografia de superfície, sempre focando em sistemas não-invasivos. Assumir e desenvolver protocolos de aquisição seguindo diretrizes fundamentadas e protocoladas para sEMG, como por exemplo, o projeto SENIAM. Implementar o sistema atual considerando o conceito onde as linguagens de programação, os hardwares e softwares sejam livres, *open source*.

Melhorar a estrutura da interface, de forma a se auto adaptar independentemente do usuário, reduzir o número de canais e aumentar a quantidade de tarefas realizadas nas gravações do HDsEMG. Explorar e aplicar mais tipos de modelos de redes neurais convolucionais profundas, implementar um sistema *real-time* para extração de características, utilizando *labelling* e *overlapping*.

Considerando isso, torna-se um caminho promissor para pesquisas futuras podendo auxiliar na redução das altas taxas de rejeições das próteses mioelétricas comerciais. E com o avanço das pesquisas pode-se considerar um futuro onde essas próteses apresentarão

restaurações somatossensoriais e interações com interfaces neurais, capazes de promover o controle e acionamento de dispositivos pelas ações e funções cerebrais voluntárias, gerando e promovendo assim, uma ampla qualidade de vida aos seus usuários.

REFERÊNCIAS

- AGARWAL-HARDING, K. J. *et al.* Understanding and addressing the global need for orthopaedic trauma care. **JBJS**, v. 98, n. 21, p. 1844–1853, 2016. Citado na página 19.
- AHMAD, N. *et al.* Lower limb amputation in england: prevalence, regional variation and relationship with revascularisation, deprivation and risk factors. a retrospective review of hospital data. **Journal of the Royal Society of Medicine**, v. 107, n. 12, p. 483–489, 2014. Citado na página 19.
- AHMADIZADEH, C. *et al.* Toward intuitive prosthetic control: solving common issues using force myography, surface electromyography, and pattern recognition in a pilot case study. **IEEE robotics & automation magazine**, v. 24, n. 4, p. 102–111, 2017. Citado na página 19.
- AHMED, K. T. *et al.* Maximum response deep learning using markov, retinal & primitive patch binding with googlenet & vgg-19 for large image retrieval. **IEEE Access**, v. 9, p. 41934–41957, 2021. Citado na página 113.
- AKHTAR, N.; RAGAVENDRAN, U. Interpretation of intelligence in cnn-pooling processes: a methodological survey. **Neural computing and applications**, v. 32, n. 3, p. 879–898, 2020. Citado 2 vezes nas páginas 72 e 73.
- ALO, K. M.; HOLSHEIMER, J. New trends in neuromodulation for the management of neuropathic pain. **Neurosurgery**, v. 50, n. 4, p. 690–704, 2002. Citado na página 45.
- ALPENFELS, E. J. The anthropology and social significance of the human hand. **Artificial limbs**, v. 2, n. 2, p. 4–21, 1955. Citado na página 21.
- AMBROSE, R. O. *et al.* Robonaut: Nasa’s space humanoid. **IEEE Intelligent Systems and Their Applications**, v. 15, n. 4, p. 57–63, 2000. Citado na página 30.
- AMMA, C. *et al.* Advancing muscle-computer interfaces with high-density electromyography. *In: Proceedings of the 33rd Annual ACM Conference on Human Factors in Computing Systems*. [S.l.: s.n.], 2015. p. 929–938. Citado na página 36.
- ANDERSEN, R. A.; ESSICK, G. K.; SIEGEL, R. M. Encoding of spatial location by posterior parietal neurons. **Science**, v. 230, n. 4724, p. 456–458, 1985. Citado na página 42.
- 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**, v. 10, p. 9, 2016. Citado 2 vezes nas páginas 71 e 72.
- ATZORI, M. *et al.* Characterization of a benchmark database for myoelectric movement classification. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 23, n. 1, p. 73–83, 2014. Citado na página 60.
- BAHADOR, A. *et al.* High accurate lightweight deep learning method for gesture recognition based on surface electromyography. **Computer Methods and Programs in Biomedicine**, v. 195, p. 105643, 2020. Citado 2 vezes nas páginas 38 e 39.

- BARSOTTI, M. *et al.* Online finger control using high-density emg and minimal training data for robotic applications. **IEEE Robotics and Automation Letters**, v. 4, n. 2, p. 217–223, 2018. Citado na página 38.
- BASHA, S. S. *et al.* Impact of fully connected layers on performance of convolutional neural networks for image classification. **Neurocomputing**, v. 378, p. 112–119, 2020. Citado na página 73.
- BEGG, R.; KAMRUZZAMAN, J. Neural networks for detection and classification of walking pattern changes due to ageing. **Australasian Physics & Engineering Sciences in Medicine**, v. 29, n. 2, p. 188, 2006. Citado na página 98.
- BEHRENDT, C.-A. *et al.* International variations in amputation practice: a vasconet report. **European Journal of Vascular and Endovascular Surgery**, v. 56, n. 3, p. 391–399, 2018. Citado na página 19.
- BELTER, J. T.; SEGIL, J. L.; SM, B. Mechanical design and performance specifications of anthropomorphic prosthetic hands: a review. **Journal of rehabilitation research and development**, v. 50, n. 5, p. 599, 2013. Citado na página 18.
- BENSMAIA, S. J.; TYLER, D. J.; MICERA, S. Restoration of sensory information via bionic hands. **Nature Biomedical Engineering**, p. 1–13, 2020. Citado na página 18.
- BERGER, H. Uber das electrenkephalogram des menchen viii. **Arch. Psychiat. Nervenkr**, v. 101, p. 452, 1935. Citado na página 42.
- BICCHI, A. Hands for dexterous manipulation and robust grasping: A difficult road toward simplicity. **IEEE Transactions on robotics and automation**, v. 16, n. 6, p. 652–662, 2000. Citado na página 28.
- BOGEY, R. A.; BARNES, L. A.; PERRY, J. Computer algorithms to characterize individual subject emg profiles during gait. **Archives of physical medicine and rehabilitation**, v. 73, n. 9, p. 835–841, 1992. Citado na página 59.
- BORGES, A. F. *et al.* The strategic use of artificial intelligence in the digital era: Systematic literature review and future research directions. **International Journal of Information Management**, v. 57, p. 102225, 2021. Citado na página 65.
- BORTON, D. *et al.* Personalized neuroprosthetics. **Science translational medicine**, v. 5, n. 210, p. 210rv2–210rv2, 2013. Citado na página 18.
- BOSCHMANN, A. *et al.* A zynq-based dynamically reconfigurable high density myoelectric prosthesis controller. *In: IEEE. Design, Automation & Test in Europe Conference & Exhibition (DATE)*, 2017. [S.l.], 2017. p. 1002–1007. Citado na página 36.
- BRADLEY, A. P. The use of the area under the roc curve in the evaluation of machine learning algorithms. **Pattern recognition**, v. 30, n. 7, p. 1145–1159, 1997. Citado na página 97.
- BUONARROTI, M. **The Creation of Adam**. [S.l.: s.n.], 1475. Fresco. Citado na página 24.

- BUTTERFASS, J. *et al.* Dlr-hand ii: Next generation of a dextrous robot hand. *In: IEEE. Proceedings 2001 ICRA. IEEE International Conference on Robotics and Automation (Cat. No. 01CH37164). [S.l.], 2001. v. 1, p. 109–114. Citado na página 29.*
- CARVALHO, J. de S.; SENA, A. R. de; NETO, A. C. B. Epidemiologia das amputações traumáticas atendidas em hospital público de referência em traumatologia e ortopedia. **Brazilian Journal of Development**, v. 6, n. 5, p. 25068–25078, 2020. Citado na página 20.
- CASTIELLO, U. The neuroscience of grasping. **Nature Reviews Neuroscience**, v. 6, n. 9, p. 726–736, 2005. Citado na página 18.
- CATTARELLO, P.; MERLETTI, R. Characterization of dry and wet electrode-skin interfaces on different skin treatments for hdsemg. *In: IEEE. 2016 IEEE International Symposium on Medical Measurements and Applications (MeMeA). [S.l.], 2016. p. 1–6. Citado na página 56.*
- CHAPIN, J. K. *et al.* Real-time control of a robot arm using simultaneously recorded neurons in the motor cortex. **Nature neuroscience**, v. 2, n. 7, p. 664–670, 1999. Citado na página 42.
- CHEN, C. *et al.* Prediction of finger kinematics from discharge timings of motor units: implications for intuitive control of myoelectric prostheses. **Journal of neural engineering**, v. 16, n. 2, p. 026005, 2019. Citado 2 vezes nas páginas 36 e 37.
- CHEN, J. *et al.* High-density surface emg-based gesture recognition using a 3d convolutional neural network. **Sensors**, v. 20, n. 4, p. 1201, 2020. Citado 2 vezes nas páginas 38 e 39.
- CHOWDHURY, R. H. *et al.* Surface electromyography signal processing and classification techniques. **Sensors**, v. 13, n. 9, p. 12431–12466, 2013. Citado na página 64.
- CLARKE, A. K. *et al.* Deep learning for robust decomposition of high-density surface emg signals. **IEEE Transactions on Biomedical Engineering**, v. 68, n. 2, p. 526–534, 2020. Citado na página 38.
- CONNOLLY, C. Prosthetic hands from touch bionics. **Industrial Robot: An International Journal**, 2008. Citado na página 30.
- DAI, C.; CAO, Y.; HU, X. Estimation of finger joint angle based on neural drive extracted from high-density electromyography. *In: IEEE. 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). [S.l.], 2018. p. 4820–4823. Citado na página 37.*
- DALEY, H. *et al.* High density electromyography data of normally limbed and transradial amputee subjects for multifunction prosthetic control. **Journal of Electromyography and Kinesiology**, v. 22, n. 3, p. 478–484, 2012. Citado 2 vezes nas páginas 35 e 36.
- DALEY, H.; ENGLEHART, K.; KURUGANTI, U. Muscle activation patterns of the forearm: high-density electromyography data of normally limbed and transradial amputee subjects. **JPO: Journal of Prosthetics and Orthotics**, v. 22, n. 4, p. 244–251, 2010. Citado 2 vezes nas páginas 35 e 36.

- D'ANNA, E. **Designing sensory feedback approaches for restoring touch and position feedback in upper limb amputees**. [S.l.], 2018. Citado 7 vezes nas páginas 18, 24, 25, 26, 28, 32 e 46.
- DENG, L.; YU, D. Deep learning: methods and applications. **Foundations and trends in signal processing**, v. 7, n. 3-4, p. 197-387, 2014. Citado na página 68.
- DESMOND, D. M. Coping, affective distress, and psychosocial adjustment among people with traumatic upper limb amputations. **Journal of psychosomatic research**, v. 62, n. 1, p. 15-21, 2007. Citado 2 vezes nas páginas 24 e 25.
- DIMITROV, G. V.; DIMITROVA, N. A. Precise and fast calculation of the motor unit potentials detected by a point and rectangular plate electrode. **Medical engineering & physics**, v. 20, n. 5, p. 374-381, 1998. Citado na página 51.
- DO, C. B.; NG, A. Y. Transfer learning for text classification. **Advances in neural information processing systems**, v. 18, p. 299-306, 2005. Citado na página 66.
- DONOGHUE, J. P. Connecting cortex to machines: recent advances in brain interfaces. **Nature neuroscience**, v. 5, n. 11, p. 1085-1088, 2002. Citado 2 vezes nas páginas 44 e 45.
- DOWNEY, J. E.; BROOKS, J.; BENSMAIA, S. J. Artificial sensory feedback for bionic hands. *In: Intelligent Biomechanics in Neurorehabilitation*. [S.l.]: Elsevier, 2020. p. 131-145. Citado na página 44.
- ESQUENAZI, A. Amputation rehabilitation and prosthetic restoration. from surgery to community reintegration. **Disability and rehabilitation**, v. 26, n. 14-15, p. 831-836, 2004. Citado na página 24.
- FABIO, R. P. D. Reliability of computerized surface electromyography for determining the onset of muscle activity. **Physical therapy**, v. 67, n. 1, p. 43-48, 1987. Citado na página 59.
- FAJARDO, J. *et al.* Galileo hand: An anthropomorphic and affordable upper-limb prosthesis. **IEEE access**, v. 8, p. 81365-81377, 2020. Citado na página 30.
- FARINA, D.; MERLETTI, R. A novel approach for precise simulation of the emg signal detected by surface electrodes. **IEEE transactions on biomedical engineering**, v. 48, n. 6, p. 637-646, 2001. Citado 2 vezes nas páginas 51 e 54.
- FARINA, D.; RAINOLDI, A. Compensation of the effect of sub-cutaneous tissue layers on surface emg: a simulation study. **Medical engineering & physics**, v. 21, n. 6-7, p. 487-497, 1999. Citado na página 53.
- FORERO, F. R. C. Sistema baropodométrico e classificação de escoliose utilizando técnicas de machine learning. 2019. Citado 2 vezes nas páginas 96 e 97.
- FRANSSON-HALL, C.; KILBOM, Å. Sensitivity of the hand to surface pressure. **Applied ergonomics**, v. 24, n. 3, p. 181-189, 1993. Citado na página 23.
- FRANZKE, A. W. *et al.* Users' and therapists' perceptions of myoelectric multi-function upper limb prostheses with conventional and pattern recognition control. **PLoS One**, v. 14, n. 8, p. e0220899, 2019. Citado na página 18.

FUGLEVAND, A. J.; WINTER, D. A.; PATLA, A. E. Models of recruitment and rate coding organization in motor-unit pools. **Journal of neurophysiology**, v. 70, n. 6, p. 2470–2488, 1993. Citado na página 50.

FUGLEVAND, A. J. *et al.* Detection of motor unit action potentials with surface electrodes: influence of electrode size and spacing. **Biological cybernetics**, v. 67, n. 2, p. 143–153, 1992. Citado na página 50.

GENG, Y. *et al.* A novel channel selection method for multiple motion classification using high-density electromyography. **Biomedical engineering online**, v. 13, n. 1, p. 1–16, 2014. Citado na página 36.

GHAFOOR, U.; KIM, S.; HONG, K.-S. Selectivity and longevity of peripheral-nerve and machine interfaces: a review. **Frontiers in Neurorobotics**, v. 11, p. 59, 2017. Citado 3 vezes nas páginas 46, 47 e 48.

GIORGI, S. D. **Evaluation of High-Density EMG Feature Extraction and Selection to Recognize Lower Limbs Movements for a Rehabilitation Exoskeleton**. Tese (Doutorado) — Politecnico di Torino, 2018. Citado na página 56.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S.l.]: MIT Press, 2016. <http://www.deeplearningbook.org>. Citado 2 vezes nas páginas 69 e 70.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep learning (adaptive computation and machine learning series). **Cambridge Massachusetts**, p. 321–359, 2017. Citado 2 vezes nas páginas 67 e 76.

GOUTTE, C.; GAUSSIÉ, E. A probabilistic interpretation of precision, recall and f-score, with implication for evaluation. *In*: SPRINGER. European conference on information retrieval. [S.l.], 2005. p. 345–359. Citado na página 98.

GRACZYK, E. L. *et al.* The neural basis of perceived intensity in natural and artificial touch. **Science translational medicine**, v. 8, n. 362, p. 362ra142–362ra142, 2016. Citado na página 18.

GRAY, H.; STANDRING, S. **Gray’s anatomy: the anatomical basis of clinical practice**. [S.l.]: Churchill Livingstone, 2008. Citado na página 33.

HA, N.; WITHANACHCHI, G. P.; YIHUN, Y. Performance of forearm fmg for estimating hand gestures and prosthetic hand control. **Journal of Bionic Engineering**, v. 16, n. 1, p. 88–98, 2019. Citado na página 38.

HARGROVE, L.; ENGLEHART, K.; HUDGINS, B. A training strategy to reduce classification degradation due to electrode displacements in pattern recognition based myoelectric control. **Biomedical signal processing and control**, v. 3, n. 2, p. 175–180, 2008. Citado na página 35.

HARTWELL, A. **Machine Learning for Hand Gesture Classification from Surface Electromyography Signals**. Tese (Doutorado) — University of Sheffield, 2019. Citado na página 60.

HE, J. *et al.* Electrode density affects the robustness of myoelectric pattern recognition system with and without electrode shift. **IEEE journal of biomedical and health informatics**, v. 23, n. 1, p. 156–163, 2018. Citado na página 37.

- HEIDUSCHKA, P.; THANOS, S. Implantable bioelectronic interfaces for lost nerve functions. **Progress in neurobiology**, v. 55, n. 5, p. 433–461, 1998. Citado na página 46.
- HERMENS, H.; MERLETTI, R.; FRERIKS, B. European activities on surface electromyography. *In: Proceedings of the first general SENIAM (Surface EMG for Non Invasive Assessment of Muscles) workshop. [S.l.: s.n.]*, 1996. Citado na página 49.
- HIROSE, M.; OGAWA, K. Honda humanoid robots development. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 365, n. 1850, p. 11–19, 2007. Citado na página 30.
- HODGES, P. W.; BUI, B. H. A comparison of computer-based methods for the determination of onset of muscle contraction using electromyography. **Electroencephalography and Clinical Neurophysiology/Electromyography and Motor Control**, v. 101, n. 6, p. 511–519, 1996. Citado na página 59.
- HOLOBAR, A.; ZAZULA, D. Gradient convolution kernel compensation applied to surface electromyograms. *In: SPRINGER. International Conference on Independent Component Analysis and Signal Separation. [S.l.]*, 2007. p. 617–624. Citado na página 35.
- HUANG, H. *et al.* Spatial filtering improves emg classification accuracy following targeted muscle reinnervation. **Annals of biomedical engineering**, v. 37, n. 9, p. 1849–1857, 2009. Citado na página 35.
- HUDGINS, B.; PARKER, P.; SCOTT, R. N. A new strategy for multifunction myoelectric control. **IEEE transactions on biomedical engineering**, v. 40, n. 1, p. 82–94, 1993. Citado na página 58.
- HYVÄRINEN, A.; HURRI, J.; HOYER, P. O. Principal components and whitening. *In: Natural Image Statistics. [S.l.]: Springer*, 2009. p. 93–130. Citado na página 60.
- IOFFE, S.; SZEGEDY, C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *In: PMLR. International conference on machine learning. [S.l.]*, 2015. p. 448–456. Citado na página 77.
- ISLAM, M. R. *et al.* S-convnet: A shallow convolutional neural network architecture for neuromuscular activity recognition using instantaneous high-density surface emg images. *In: IEEE. 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). [S.l.]*, 2020. p. 744–749. Citado 2 vezes nas páginas 38 e 39.
- ISLAM, M. R.; MASSICOTTE, D.; ZHU, W.-P. All-convnet: A lightweight all cnn for neuromuscular activity recognition using instantaneous high-density surface emg images. *In: IEEE. 2020 IEEE International Instrumentation and Measurement Technology Conference (I2MTC). [S.l.]*, 2020. p. 1–6. Citado 2 vezes nas páginas 38 e 39.
- IVES, J. C.; WIGGLESWORTH, J. K. Sampling rate effects on surface emg timing and amplitude measures. **Clinical biomechanics**, v. 18, n. 6, p. 543–552, 2003. Citado na página 60.
- JARQUE-BOU, N. J. *et al.* Identification of forearm skin zones with similar muscle activation patterns during activities of daily living. **Journal of neuroengineering and rehabilitation**, v. 15, n. 1, p. 1–11, 2018. Citado na página 37.

- JOSEPH, A. B. Design considerations for the brain-machine interface. **Medical hypotheses**, v. 17, n. 3, p. 191–195, 1985. Citado na página 42.
- JUNG, W. *et al.* Restructuring batch normalization to accelerate cnn training. **Proceedings of Machine Learning and Systems**, v. 1, p. 14–26, 2019. Citado na página 77.
- KAPANDJI, A. **Fisiologia Articular (Membro Superior) Vol I 5ª Edição**. [S.l.]: Guanabara Koogan, Rio de Janeiro, 2000. Citado na página 21.
- KAPELNER, T. *et al.* Decoding motor unit activity from forearm muscles: perspectives for myoelectric control. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 26, n. 1, p. 244–251, 2017. Citado na página 37.
- KRISHNA, S. T.; KALLURI, H. K. Deep learning and transfer learning approaches for image classification. **International Journal of Recent Technology and Engineering (IJRTE)**, v. 7, n. 5S4, p. 427–432, 2019. Citado na página 113.
- KRUG, E. G.; SHARMA, G. K.; LOZANO, R. The global burden of injuries. **American journal of public health**, v. 90, n. 4, p. 523, 2000. Citado na página 19.
- LAUER, R. T. *et al.* Applications of cortical signals to neuroprosthetic control: a critical review. **IEEE transactions on rehabilitation engineering**, v. 8, n. 2, p. 205–208, 2000. Citado na página 45.
- LEAKEY, L. S.; TOBIAS, P. V.; NAPIER, J. R. A new species of the genus homo from olduvai gorge. **Nature**, v. 202, n. 4927, p. 7–9, 1964. Citado na página 23.
- LEBEDEV, M. A.; NICOLELIS, M. A. Brain-machine interfaces: past, present and future. **TRENDS in Neurosciences**, v. 29, n. 9, p. 536–546, 2006. Citado 2 vezes nas páginas 42 e 43.
- LEBEDEV, M. A.; NICOLELIS, M. A. Brain-machine interfaces: From basic science to neuroprostheses and neurorehabilitation. **Physiological reviews**, v. 97, n. 2, p. 767–837, 2017. Citado na página 42.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **nature**, v. 521, n. 7553, p. 436–444, 2015. Citado 2 vezes nas páginas 68 e 69.
- LECUN, Y. *et al.* Handwritten digit recognition with a back-propagation network. **Advances in neural information processing systems**, v. 2, 1989. Citado na página 73.
- LECUN, Y. *et al.* Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278–2324, 1998. Citado na página 73.
- LENT, R. Cem bilhões de neurônios: conceitos fundamentais de neurociência. *In: Cem bilhões de neurônios: conceitos fundamentais de neurociência*. [S.l.: s.n.], 2004. p. 698–698. Citado na página 45.
- LI, H. *et al.* Cnn-based ranking for biomedical entity normalization. **BMC bioinformatics**, v. 18, n. 11, p. 79–86, 2017. Citado 2 vezes nas páginas 76 e 77.

- LIAROKAPIS, M. *et al.* Openbionics: An open-source initiative for the creation of affordable, modular, light-weight, underactuated robot hands and prosthetic devices. 2014. Citado na página 30.
- LIEBER, J. D.; BENSMAIA, S. J. Emergence of an invariant representation of texture in primate somatosensory cortex. **Cerebral Cortex**, v. 30, n. 5, p. 3228–3239, 2020. Citado na página 44.
- LIN, C. *et al.* Robust extraction of basis functions for simultaneous and proportional myoelectric control via sparse non-negative matrix factorization. **Journal of neural engineering**, v. 15, n. 2, p. 026017, 2018. Citado na página 37.
- LIU, M. *et al.* Deep learning based on batch normalization for p300 signal detection. **Neurocomputing**, v. 275, p. 288–297, 2018. Citado na página 77.
- LUCA, C. J. D.; CONTESSA, P. Hierarchical control of motor units in voluntary contractions. **Journal of neurophysiology**, v. 107, n. 1, p. 178–195, 2012. Citado na página 50.
- LUCHETTI, M. *et al.* Impact of michelangelo prosthetic hand: Findings from a crossover longitudinal study. **Journal of Rehabilitation Research & Development**, v. 52, n. 5, 2015. Citado na página 30.
- MADURI, P.; AKHONDI, H. Upper limb amputation. 2019. Citado na página 26.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, n. 4, p. 115–133, 1943. Citado na página 70.
- MCDONALD, C. L. *et al.* Global prevalence of traumatic non-fatal limb amputation. **Prosthetics and orthotics international**, p. 0309364620972258, 2020. Citado 4 vezes nas páginas 19, 25, 26 e 27.
- MEDYNSKI, C.; RATTRAY, B. Bionic prosthetic design. *In: Myoelectric Symposium*. [S.l.: s.n.], 2011. Citado na página 30.
- MENDEZ, V. *et al.* Current solutions and future trends for robotic prosthetic hands. **Annual Review of Control, Robotics, and Autonomous Systems**, v. 4, p. 595–627, 2021. Citado 3 vezes nas páginas 18, 28 e 29.
- MERLETTI, R. The electrode–skin interface and optimal detection of bioelectric signals. **Physiological measurement**, v. 31, n. 10, 2010. Citado na página 55.
- MERLETTI, R. *et al.* Advances in surface emg: recent progress in clinical research applications. **Critical Reviews™ in Biomedical Engineering**, v. 38, n. 4, 2010. Citado na página 55.
- MERLETTI, R. *et al.* Technology and instrumentation for detection and conditioning of the surface electromyographic signal: state of the art. **Clinical biomechanics**, v. 24, n. 2, p. 122–134, 2009. Citado na página 55.
- MERLETTI, R. *et al.* Surface electromyography: Barriers limiting widespread use of semg in clinical assessment and neurorehabilitation. **Frontiers in Neurology**, v. 12, 2021. Citado na página 55.

- MERLETTI, R.; CERONE, G. Tutorial. surface emg detection, conditioning and pre-processing: best practices. **Journal of Electromyography and Kinesiology**, v. 54, p. 102440, 2020. Citado 3 vezes nas páginas 20, 48 e 49.
- MERLETTI, R.; HOLOBAR, A.; FARINA, D. Analysis of motor units with high-density surface electromyography. **Journal of electromyography and kinesiology**, v. 18, n. 6, p. 879–890, 2008. Citado na página 35.
- MERLETTI, R.; MUCELI, S. Tutorial. surface emg detection in space and time: Best practices. **Journal of Electromyography and Kinesiology**, v. 49, p. 102363, 2019. Citado na página 49.
- MERLETTI, R.; PARKER, P. J. **Electromyography: physiology, engineering, and non-invasive applications**. [S.l.]: John Wiley & Sons, 2004. v. 11. Citado na página 54.
- MEYER, T. M. Psychological aspects of mutilating hand injuries. **Hand Clinics**, v. 19, n. 1, p. 41–49, 2003. Citado 4 vezes nas páginas 18, 19, 24 e 25.
- MICERA, S.; NAVARRO, X. Bidirectional interfaces with the peripheral nervous system. **International review of neurobiology**, v. 86, p. 23–38, 2009. Citado 2 vezes nas páginas 45 e 46.
- MOHER, D. *et al.* Preferred reporting items for systematic review and meta-analysis protocols (prisma-p) 2015 statement. **Systematic reviews**, v. 4, n. 1, p. 1–9, 2015. Citado na página 78.
- MOIN, A. *et al.* Adaptive emg-based hand gesture recognition using hyperdimensional computing. **Human–Comput. Interact.**, 2019. Citado na página 38.
- MOIN, A. *et al.* An emg gesture recognition system with flexible high-density sensors and brain-inspired high-dimensional classifier. *In: IEEE. 2018 IEEE International Symposium on Circuits and Systems (ISCAS)*. [S.l.], 2018. p. 1–5. Citado na página 37.
- MOINI, M. *et al.* Patterns of extremity traumas leading to amputation in iran: results of iranian national trauma project. **Chinese Journal of Traumatology (English Edition)**, v. 12, n. 2, p. 77–80, 2009. Citado na página 19.
- MORSTATTER, F. *et al.* A new approach to bot detection: striking the balance between precision and recall. *In: IEEE. 2016 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM)*. [S.l.], 2016. p. 533–540. Citado na página 98.
- MOXON, K. A. *et al.* **Designing a brain-machine interface for neuroprosthetic control**. [S.l.]: CRC Press: Boca Raton, FL, USA, 2000. Citado na página 42.
- NAIK, G. R. *et al.* Principal component analysis applied to surface electromyography: a comprehensive review. **IEEE Access**, v. 4, p. 4025–4037, 2016. Citado na página 62.
- NAM, N. T.; HUNG, P. D. Padding methods in convolutional sequence model: an application in japanese handwriting recognition. *In: Proceedings of the 3rd International Conference on Machine Learning and Soft Computing*. [S.l.: s.n.], 2019. p. 138–142. Citado na página 72.

NAPIER, J. Fossil hand bones from olduvai gorge. **Nature**, v. 196, n. 4853, p. 409–411, 1962. Citado na página 23.

NAVARRO, X. *et al.* A critical review of interfaces with the peripheral nervous system for the control of neuroprostheses and hybrid bionic systems. **Journal of the Peripheral Nervous System**, v. 10, n. 3, p. 229–258, 2005. Citado na página 47.

NEGI, S.; KUMAR, Y.; MISHRA, V. Feature extraction and classification for emg signals using linear discriminant analysis. *In: IEEE. 2016 2nd International Conference on Advances in Computing, Communication, & Automation (ICACCA)(Fall)*. [S.l.], 2016. p. 1–6. Citado 2 vezes nas páginas 57 e 58.

NICOLELIS, M. A. Actions from thoughts. **Nature**, v. 409, n. 6818, p. 403–407, 2001. Citado na página 45.

NOCE, E. *et al.* Emg and eng-envelope pattern recognition for prosthetic hand control. **Journal of Neuroscience Methods**, v. 311, p. 38–46, 2019. Citado na página 38.

OLIVEIRA, L. M. B. *et al.* Cartilha do censo 2010: pessoas com deficiência. 2012. Citado na página 19.

OLSSON, A. semg classification with convolutional neural networks: A multi-label approach for prosthetic hand control. 2018. Citado 2 vezes nas páginas 73 e 74.

PAGE, D. M. *et al.* Motor control and sensory feedback enhance prosthesis embodiment and reduce phantom pain after long-term hand amputation. **Frontiers in human neuroscience**, v. 12, p. 352, 2018. Citado na página 46.

PAN, L. *et al.* Improving robustness against electrode shift of high density emg for myoelectric control through common spatial patterns. **Journal of neuroengineering and rehabilitation**, v. 12, n. 1, p. 1–16, 2015. Citado na página 36.

PARRY-HILL, J. *et al.* Understanding volunteer at fabricators: opportunities and challenges in diy-at for others in e-nable. *In: Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems*. [S.l.: s.n.], 2017. p. 6184–6194. Citado na página 30.

PEIXOTO, A. M. *et al.* Prevalência de amputações de membros superiores e inferiores no estado de alagoas atendidos pelo sus entre 2008 e 2015. **Fisioterapia e Pesquisa**, v. 24, p. 378–384, 2017. Citado 2 vezes nas páginas 20 e 24.

PETERSEN, E.; ROSTALSKI, P. A comprehensive mathematical model of surface electromyography and force generation. **bioRxiv**, p. 273458, 2018. Citado na página 54.

PETRINI, F. M. *et al.* Six-month assessment of a hand prosthesis with intraneural tactile feedback. **Annals of neurology**, v. 85, n. 1, p. 137–154, 2019. Citado na página 46.

PHINYOMARK, A.; LIMSAKUL, C.; PHUKPATTARANONT, P. Application of wavelet analysis in emg feature extraction for pattern classification. **Measurement Science Review**, v. 11, n. 2, p. 45, 2011. Citado na página 57.

PHINYOMARK, A.; PHUKPATTARANONT, P.; LIMSAKUL, C. Feature reduction and selection for emg signal classification. **Expert systems with applications**, v. 39, n. 8, p. 7420–7431, 2012. Citado na página 57.

- PIAZZA, C. *et al.* A century of robotic hands. **Annual Review of Control, Robotics, and Autonomous Systems**, v. 2, p. 1–32, 2019. Citado 3 vezes nas páginas 18, 28 e 30.
- PIERELLA, C. *et al.* Personalizing exoskeleton-based upper limb rehabilitation using a statistical model: a pilot study. *In*: SPRINGER. International Conference on NeuroRehabilitation. [S.l.], 2018. p. 117–121. Citado na página 46.
- PIERRIE, S. N.; GASTON, R. G.; LOEFFLER, B. J. Current concepts in upper-extremity amputation. **The Journal of hand surgery**, v. 43, n. 7, p. 657–667, 2018. Citado na página 26.
- PIERVIRGILI, G.; PETRACCA, F.; MERLETTI, R. A new method to assess skin treatments for lowering the impedance and noise of individual gelled ag–agcl electrodes. **Physiological measurement**, v. 35, n. 10, p. 2101, 2014. Citado na página 56.
- PILLET, J.; DIDIERJEAN-PILLET, A. Aesthetic hand prosthesis: gadget or therapy? presentation of a new classification. **The Journal of Hand Surgery: British & European Volume**, v. 26, n. 6, p. 523–528, 2001. Citado na página 24.
- PINZÓN-ARENAS, J. O.; JIMÉNEZ-MORENO, R.; RUBIANO, A. Percentage estimation of muscular activity of the forearm by means of emg signals based on the gesture recognized using cnn. **Sensing and Bio-Sensing Research**, v. 29, p. 100353, 2020. Citado na página 71.
- PLONSEY, R.; BARR, R. C. **Bioelectricity: a quantitative approach**. [S.l.]: Springer Science & Business Media, 2007. Citado na página 52.
- PRESTON, D. C.; SHAPIRO, B. E. **Electromyography and neuromuscular disorders e-book: clinical-electrophysiologic correlations (Expert Consult-Online)**. [S.l.]: Elsevier Health Sciences, 2012. Citado na página 52.
- PROCHAZKA, A.; MUSHAHWAR, V. K.; MCCREERY, D. B. Neural prostheses. **The Journal of physiology**, v. 533, n. 1, p. 99–109, 2001. Citado na página 45.
- RAINA, R. *et al.* Self-taught learning: transfer learning from unlabeled data. *In*: Proceedings of the 24th international conference on Machine learning. [S.l.: s.n.], 2007. p. 759–766. Citado na página 66.
- RASPOPOVIC, S. *et al.* Neural signal recording and processing in somatic neuroprosthetic applications. a review. **Journal of neuroscience methods**, v. 337, p. 108653, 2020. Citado na página 45.
- RESNIK, L. *et al.* Prosthesis satisfaction in a national sample of veterans with upper limb amputation. **Prosthetics and orthotics international**, v. 44, n. 2, p. 81–91, 2020. Citado na página 26.
- ROJAS-MARTÍNEZ, M.; MAÑANAS, M. A.; ALONSO, J. F. High-density surface emg maps from upper-arm and forearm muscles. **Journal of neuroengineering and rehabilitation**, v. 9, n. 1, p. 1–17, 2012. Citado na página 36.
- SAAL, H. P.; BENSMAIA, S. J. Biomimetic approaches to bionic touch through a peripheral nerve interface. **Neuropsychologia**, v. 79, p. 344–353, 2015. Citado na página 18.

- SAMUEL, O. W. *et al.* Pattern recognition of electromyography signals based on novel time domain features for amputees' limb motion classification. **Computers & Electrical Engineering**, v. 67, p. 646–655, 2018. Citado na página 37.
- SCHOTT, G. D. Penfield's homunculus: a note on cerebral cartography. **Journal of neurology, neurosurgery, and psychiatry**, v. 56, n. 4, p. 329, 1993. Citado na página 45.
- SEARLE, A.; KIRKUP, L. A direct comparison of wet, dry and insulating bioelectric recording electrodes. **Physiological measurement**, v. 21, n. 2, p. 271, 2000. Citado na página 56.
- SEIBOLD, C. *et al.* Detection of face morphing attacks by deep learning. *In*: SPRINGER. International Workshop on Digital Watermarking. [S.l.], 2017. p. 107–120. Citado na página 113.
- SELFSLAGH, A. *et al.* Non-invasive, brain-controlled functional electrical stimulation for locomotion rehabilitation in individuals with paraplegia. **Scientific reports**, v. 9, n. 1, p. 1–17, 2019. Citado na página 46.
- SHANECHI, M. M. Brain-machine interface control algorithms. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 25, n. 10, p. 1725–1734, 2016. Citado 2 vezes nas páginas 43 e 44.
- SHAW, J. *et al.* Quality of life and complications in lower limb amputees in tanzania: results from a pilot study. **The Lancet Global Health**, v. 6, p. S18, 2018. Citado na página 19.
- SHIFFMAN, M. *et al.* **De Anima: On the Soul**. [S.l.]: Hackett Publishing, 2012. Citado na página 21.
- SHIN, H.; HU, X. Flexibility of finger activation patterns elicited through non-invasive multi-electrode nerve stimulation. *In*: IEEE. 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). [S.l.], 2018. p. 1428–1431. Citado na página 37.
- SHLENS, J. A tutorial on principal component analysis. **arXiv preprint arXiv:1404.1100**, 2014. Citado na página 62.
- SHOKUR, S. *et al.* A modular strategy for next-generation upper-limb sensory-motor neuroprostheses. **Med**, 2021. Citado 2 vezes nas páginas 18 e 20.
- SIMÕES, A.; ATHIAS, L.; BOTELHO, L. **Panorama nacional e internacional da produção de indicadores sociais: grupos populacionais específicos e uso do tempo**. [S.l.]: IBGE, Instituto Brasileiro de Geografia e Estatística, 2018. Citado na página 25.
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014. Citado na página 95.
- SMITH, L. I. A tutorial on principal components analysis. 2002. Citado na página 62.

- SOUZA, Y. P. d.; SANTOS, A. C. O. d.; ALBUQUERQUE, L. C. d. Caracterização das pessoas amputadas de um hospital de grande porte em recife (pe, brasil). **Jornal Vascular Brasileiro**, v. 18, 2019. Citado na página 20.
- STACHACZYK, M.; ATASHZAR, S. F.; FARINA, D. Adaptive spatial filtering of high-density emg for reducing the influence of noise and artefacts in myoelectric control. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 28, n. 7, p. 1511–1517, 2020. Citado 2 vezes nas páginas 38 e 39.
- STANGO, A.; NEGRO, F.; FARINA, D. Spatial correlation of high density emg signals provides features robust to electrode number and shift in pattern recognition for myocontrol. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 23, n. 2, p. 189–198, 2014. Citado na página 36.
- STAUDENMANN, D. *et al.* Improving emg-based muscle force estimation by using a high-density emg grid and principal component analysis. **IEEE Transactions on Biomedical Engineering**, v. 53, n. 4, p. 712–719, 2006. Citado na página 35.
- STAUDENMANN, D. *et al.* Towards optimal multi-channel emg electrode configurations in muscle force estimation: a high density emg study. **Journal of Electromyography and Kinesiology**, v. 15, n. 1, p. 1–11, 2005. Citado 2 vezes nas páginas 34 e 35.
- STEGEMAN, D. F. *et al.* High-density surface emg: Techniques and applications at a motor unit level. **Biocybernetics and biomedical engineering**, v. 32, n. 3, p. 3–27, 2012. Citado na página 56.
- SUBASI, A. Classification of emg signals using combined features and soft computing techniques. **Applied soft computing**, v. 12, n. 8, p. 2188–2198, 2012. Citado 2 vezes nas páginas 63 e 64.
- SUBASI, A. Classification of emg signals using pso optimized svm for diagnosis of neuromuscular disorders. **Computers in biology and medicine**, v. 43, n. 5, p. 576–586, 2013. Citado 2 vezes nas páginas 59 e 62.
- SZEGEDY, C. *et al.* Going deeper with convolutions. *In: Proceedings of the IEEE conference on computer vision and pattern recognition. [S.l.: s.n.]*, 2015. p. 1–9. Citado na página 94.
- TAN, D. W. *et al.* A neural interface provides long-term stable natural touch perception. **Science translational medicine**, v. 6, n. 257, p. 257ra138–257ra138, 2014. Citado na página 46.
- TONIN, L.; MILLÁN, J. d. R. Noninvasive brain–machine interfaces for robotic devices. **Annual Review of Control, Robotics, and Autonomous Systems**, v. 4, p. 191–214, 2021. Citado na página 43.
- TOO, J. *et al.* Emg feature selection and classification using a pbest-guide binary particle swarm optimization. **Computation**, v. 7, n. 1, p. 12, 2019. Citado na página 64.
- TORREY, L. *et al.* Handbook of research on machine learning applications and trends. **Information Science Reference, Hershey PA**, p. 242–264, 2010. Citado 2 vezes nas páginas 66 e 67.

- TUBIANA, R. **The Hand**—New York. [S.l.]: WB Saunders Publishers, 1981. Citado na página 21.
- TUBIANA, R.; THOMINE, J.-M.; MACKIN, E. Diagnóstico clínico da mão e do punho. *In: Diagnóstico clínico da mão e do punho. [S.l.: s.n.]*, 1996. p. 410–410. Citado na página 21.
- URH, F. *et al.* On the selection of neural network architecture for supervised motor unit identification from high-density surface emg. *In: IEEE. 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). [S.l.]*, 2020. p. 736–739. Citado na página 38.
- VALLE, G.; CARPANETO, J.; MICERA, S. Peripheral neural interfaces (pnis) for decoding motor intentions and encoding somatosensations in upper-limb amputees. **Handbook of Neuroengineering**, p. 1–23, 2020. Citado na página 46.
- VALLE, G. *et al.* Biomimetic intraneural sensory feedback enhances sensation naturalness, tactile sensitivity, and manual dexterity in a bidirectional prosthesis. **Neuron**, v. 100, n. 1, p. 37–45, 2018. Citado na página 46.
- VALLE, G. *et al.* Comparison of linear frequency and amplitude modulation for intraneural sensory feedback in bidirectional hand prostheses. **Scientific reports**, v. 8, n. 1, p. 1–13, 2018. Citado na página 46.
- VALLE, G. *et al.* Sensitivity to temporal parameters of intraneural tactile sensory feedback. **Journal of NeuroEngineering and Rehabilitation**, v. 17, n. 1, p. 1–12, 2020. Citado 4 vezes nas páginas 19, 32, 45 e 46.
- VECCHIO, A. D. *et al.* Tutorial: analysis of motor unit discharge characteristics from high-density surface emg signals. **Journal of Electromyography and Kinesiology**, v. 53, p. 102426, 2020. Citado na página 38.
- VECCHIO, A. D. *et al.* Associations between motor unit action potential parameters and surface emg features. **Journal of Applied Physiology**, v. 123, n. 4, p. 835–843, 2017. Citado na página 50.
- WAN, Z. *et al.* A review on transfer learning in eeg signal analysis. **Neurocomputing**, v. 421, p. 1–14, 2021. Citado na página 66.
- WANG, K. *et al.* High-density surface emg denoising using independent vector analysis. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 28, n. 6, p. 1271–1281, 2020. Citado na página 38.
- WOLPAW, J. R. *et al.* Brain-computer interface technology: a review of the first international meeting. **IEEE transactions on rehabilitation engineering**, v. 8, n. 2, p. 164–173, 2000. Citado na página 42.
- XAVIER, R. T. Implementação de uma prótese ativa para membro superior de baixo custo. 2016. Citado na página 30.
- YACOUBY, R.; AXMAN, D. Probabilistic extension of precision, recall, and f1 score for more thorough evaluation of classification models. *In: Proceedings of the First Workshop on Evaluation and Comparison of NLP Systems. [S.l.: s.n.]*, 2020. p. 79–91. Citado na página 98.

ZHANG, H. *et al.* Poseidon: An efficient communication architecture for distributed deep learning on {GPU} clusters. *In: 2017 {USENIX} Annual Technical Conference ({USENIX}{ATC} 17)*. [S.l.: s.n.], 2017. p. 181–193. Citado na página 113.

ZHANG, X.; ZHOU, P. High-density myoelectric pattern recognition toward improved stroke rehabilitation. **IEEE Transactions on Biomedical Engineering**, v. 59, n. 6, p. 1649–1657, 2012. Citado na página 36.

ZHOU, P.; RYMER, W. Z. Factors governing the form of the relation between muscle force and the emg: a simulation study. **Journal of neurophysiology**, v. 92, n. 5, p. 2878–2886, 2004. Citado na página 51.