

**UNIVERSIDADE DO VALE DO RIO DOS SINOS - UNISINOS
UNIDADE ACADÊMICA DE GRADUAÇÃO
CURSO DE ENGENHARIA ELETRÔNICA**

JOSUÉ DA SILVA BOELTER

**CLASSIFICAÇÃO DE SINAIS ELETROMIOGRÁFICOS
UTILIZANDO REDES NEURAIS ARTIFICIAIS, ANÁLISE DISCRIMINANTE
LINEAR E FLORESTA ALEATÓRIA**

SÃO LEOPOLDO - RS

2021

Josué da Silva Boelter

CLASSIFICAÇÃO DE SINAIS ELETROMIOGRÁFICOS
UTILIZANDO REDES NEURAS ARTIFICIAIS, ANÁLISE DISCRIMINANTE LINEAR
E FLORESTA ALEATÓRIA

Trabalho de Conclusão de Curso apresentado
como requisito parcial para obtenção do título de
Bacharel em Engenharia Eletrônica, pelo Curso de
Engenharia Eletrônica da Universidade do Vale do
Rio dos Sinos - UNISINOS

Orientador: Prof. Ms. João Olegário de Oliveira de
Souza

São Leopoldo - RS

2021

Dedico este trabalho a minha família, minha irmã, minha namorada, meus amigos, e principalmente, aos meus pais, que, com muito carinho e apoio, não mediram esforços para que eu chegasse até esta etapa de minha vida.

RESUMO

Existe hoje no mercado, uma defasagem de próteses para membros superiores com relação as próteses de membro inferior. Isso se deve a soma de um mercado menor, afinal apenas aproximadamente 20% das amputações feitas são de membros superiores, somado a uma maior dificuldade de desenvolvimento dessas próteses (ZIEGLER-GRAHAM, 2008) e, ainda, um elevado custo para aquisição de uma. Avanços modernos nas inteligências artificiais e acesso a processamento de dados, somados com o surgimento de *startups* e cientistas interessados em utilizar o melhor que o processamento de dados pode oferecer, garantiu um grande salto tecnológico nos modelos de próteses e uma redução considerável de custos. Nesse trabalho, tomando por base o banco de dados público Ninapro (*Non-Invasive Adaptive Hand Prosthetics*), utilizou-se três distintas técnicas de inteligência artificial, buscando descobrir qual delas é a mais promissora na classificação dos sinais mioelétricos. Os algoritmos utilizados são Redes Neurais Artificiais, Análise Discriminante Linear e Floresta Aleatória, sendo apresentado, durante o trabalho, todo o seu desenvolvimento, ajuste de parâmetros, validação e testes. Com base nos testes feitos, identificou-se a Floresta Aleatória como a mais promissora das três abordagens, alcançando uma acurácia que variou de 92% em conjuntos de 5 movimentos a 84% em conjuntos com todos os 52 movimentos trabalhados.

Palavras-chave: Prótese Mioelétrica – Eletromiografia de Superfície– Inteligência Artificial – Redes Neurais Artificiais – Floresta Aleatória

ABSTRACT

There is a gap in the upper limb prosthesis market in relation to lower limb prostheses, this is due to the sum of a smaller market, after all, only approximately 20% of amputations performed are of upper limbs, added to a greater difficulty in developing these prostheses (ZIEGLER-GRAHAM, 2008), and to make it all worse, there is still a high acquisition cost in buying one. Modern advances in artificial intelligence and access to data processing, along with the rising of startups and scientists interested in using the best that data processing can offer, ensured a great technological advance in prosthesis models and a considerable reduction in costs. In this work, based on the public database Ninapro (Non-Invasive Adaptive Hand Prosthetics), three different artificial intelligence techniques were used, seeking to discover which one is the most promising in the classification of myoelectric signals. The algorithms used are Artificial Neural Networks, Linear Discriminant Analysis and Random Forest, with all its development, parameter adjustment, validation and testing being presented during the work. Based on the tests carried out, Random Forest was identified as the most promising of the three approaches, reaching an accuracy that ranged from 92% in sets of 5 movements to 84% in sets with all 52 movements.

Keywords: Myoelectric Prosthesis - Surface Electromyography - Artificial Intelligence - Artificial Neural Network – Random Forest

LISTA DE FIGURAS

Figura 1: Níveis de amputação de membro superior.....	14
Figura 2: Anatomia óssea do membro superior.....	20
Figura 3: Anatomia muscular da porção anterior do antebraço.....	21
Figura 4: Sinal capturado e amplificado do EMG de um dedo do meio.....	26
Figura 5: Variação de tensão no músculo durante sua contração.....	27
Figura 6: Acima, as diferentes MUAPs capturadas em uma contração, abaixo a somatória destes sinais como visto pelo EMG.	28
Figura 7: Os 52 movimentos básicos do NINAPRO	30
Figura 8: Posicionamento dos equipamentos de captura para o DB1: A. Posicionamento dos eletrodos para a captura dos músculos extensores dos dedos (A.1. Sensores igualmente espaçados; A.2. Sensores reserva); B. Eletrodos para a captura dos músculos flexores dos dedos (B.1. Sensores igualmente espaçados; B.2. Sensores reserva); C. Aparência do antebraço com todos os sensores posicionados (C.1. Sensores principais igualmente espaçados; C.2. Sensores reserva; C.3. Inclinômetro; C.4. <i>Cyberglove</i> II);.....	31
Figura 9: Comparação dos dados utilizando PCA, conforme aumentam-se o número de voluntários e de posturas analisadas. Diferentes cores representam diferentes posturas.....	32
Figura 10: Demonstração da Thalmic Myo Armband, com seus 8 canais de captura e movimentos que garante identificar.....	34
Figura 11: O <i>Cyberglove</i> II e a posição dos seus sensores	35
Figura 12: O Turco Mecânico, em desenho feito por Freiherr Joseph Friedrich zu Racknitz em 1789.....	37
Figura 13: Exemplo de estrutura de uma Rede Neural Artificial.....	39
Figura 14: Estrutura de um neurônio. a. Dentrilo b. Soma c. Núcleo d. Axônio e. Bainha de mielina f. Célula de Schwann g. Nódulo de Ranvier h. Axônio Terminal.....	40
Figura 15: Estrutura do neurônio artificial.....	41
Figura 16: Representação em detalhes da unidade de processamento.	42
Figura 17: RNA com mecanismos de Feedback e inibição	43
Figura 18: Exemplo de um conjunto de dados no plano cartesiano e divididos em dois grupos.	45

Figura 19: (a) Pontos do plano bidimensionais sendo projetados sobre o eixo X1; (b) Reta unidimensional X1 com o resultado linearizado do sistema.....	46
Figura 20: (a) LDA corretamente aplicado, em relação a técnica utilizada na Figura 19, e reta ideal traçada sobre o eixo; (b) Resultado do LDA, onde é possível definir claramente o ponto que separa os dois grupos.....	47
Figura 21: Aplicação de LDA contendo três diferentes grupos.....	48
Figura 22: Exemplo de conjunto não linearizado.....	48
Figura 23: Exemplo de estrutura de uma Árvore de Decisões	50
Figura 24: Exemplo da Estrutura de uma árvore de decisão.....	52
Figura 25: Exemplo de árvore de decisão	52
Figura 26: Exemplo de uma pequena floresta aleatória	53
Figura 27: Exemplo de prótese mioelétrica de mão	55
Figura 28: Modelo da prótese mioelétrica de mão com tema do Homem de Ferro...57	
Figura 29: Modelos da prótese mioelétrica de mão da <i>Hero Arm</i>	57
Figura 30: Os diferentes modelos do LUKE Arm.....	59
Figura 31: Os diferentes grips do Luke arm: (a) Power Grip; (b) Tool Grip; (c) Fine Pinch Closed; (d) Fine Pinch Open; (e) Lateral Pinch; (f) Chuck Grip.....	60
Figura 32: Erro médio de classificação para os três diferentes conjuntos de dados. Em azul os testes com o mesmo voluntário no treino e teste. De vermelho os testes treinados com um voluntário e testado com os outros.	62
Figura 33: Relação entre <i>delay</i> de resposta e taxa de erros.....	64
Figura 34: Movimentos que a pesquisa de McIntosh buscou classificar	65
Figura 35: Validação cruzada das acurácias obtidas por McIntosh.....	66
Figura 36: Resultados obtidos para o DB1	67
Figura 37: Resultado comparando diversas <i>features</i> , classificadores e janelas	68
Figura 38: Tabela comparando diferentes propriedades e suas acurácias	68
Figura 39: Exemplo apresentado por He <i>et al</i> sobre como funciona seu sistema.....	69
Figura 40: O Otto Bock MyoBock 13E200.....	75
Figura 41: Demonstração das matrizes presentes dentro do arquivo “.mat”	75
Figura 42: Conjunto de movimentos A	76
Figura 43: Conjunto de movimentos B	77
Figura 44: Conjunto de movimentos C	78
Figura 45: Sinal captado do sEMG para o movimento de punho fechado. Cada cor representa um dos 10 sensores.	79

Figura 46: Recorte de apenas 1 dos 10 movimentos	80
Figura 47: As ondas de <i>stimulus</i> e <i>repetition</i> para o conjunto B de exercícios.....	81
Figura 48: Movimento de punho fechado, sobreposto pelas ondas de <i>stimulus</i> em verde e <i>restimulus</i> em vermelho.	82
Figura 49: Exemplo de janelamento, onde janelas de tamanho Ta se deslocam com incrementos de tamanho $Tinc$, além disso, Td representa o tempo que o sistema levar pra detectar ou classificar o movimento.	86
Figura 50: Os 52 movimentos numerados de acordo com sua sequência nos testes do banco de dados.....	89
Figura 51: Matriz de Confusão para 5 movimentos com Redes Neurais Artificiais ...	96
Figura 52: Matriz de Confusão para 12 movimentos com Redes Neurais Artificiais .	98
Figura 53: Matriz de Confusão para 20 movimentos com Redes Neurais Artificiais	100
Figura 54: Matriz de Confusão para 35 movimentos com Redes Neurais Artificiais	101
Figura 55: Matriz de Confusão para 52 movimentos com Redes Neurais Artificiais	102
Figura 56: Diagrama de caixa para os resultados com RNA.....	104
Figura 57: Matriz de Confusão para 5 movimentos com Análise Discriminante Linear.	106
Figura 58: Matriz de Confusão para 12 movimentos com Análise Discriminante Linear.	107
Figura 59: Matriz de Confusão para 20 movimentos com Análise Discriminante Linear.	109
Figura 60: Matriz de Confusão para 35 movimentos com Análise Discriminante Linear.	110
Figura 61: Matriz de Confusão para 52 movimentos com Análise Discriminante Linear.	111
Figura 62: Diagrama de caixa para os resultados com LDA.	112
Figura 63: Matriz de Confusão para 5 movimentos com Floresta Aleatória.	114
Figura 64: Matriz de Confusão para 12 movimentos com Floresta Aleatória.	115
Figura 65: Matriz de Confusão para 20 movimentos com Floresta Aleatória.	116
Figura 66: Matriz de Confusão para 35 movimentos com Floresta Aleatória.	117
Figura 67: Matriz de Confusão para 52 movimentos com Floresta Aleatória.	118
Figura 68: Diagrama de caixa para os resultados com RF.	119
Figura 69: Diagrama de caixa para os resultados dos três classificadores.....	122

LISTA DE TABELAS

Tabela 1: Características que podem ser extraídas através do sEMG dos movimentos de punho, mão e dedos.....	24
Tabela 2: Características dos voluntários.	74
Tabela 3: Métricas utilizadas, breve descrição e seu equacionamento.....	84
Tabela 4: Relação entre parâmetros do janelamento acurácia média	87
Tabela 5: Acurácia e desvio padrão da média para os 5 conjuntos de movimentos com RNA.....	103
Tabela 6: Acurácia e desvio padrão da média para os 5 conjuntos de movimentos com LDA	112
Tabela 7: Acurácia e desvio padrão da média para os 5 conjuntos de movimentos com RF	119
Tabela 8:Comparativo de acurácia entre classificadores	121
Tabela 9: Relação entre treino/teste com acurácia	124
Tabela 10: Relação entre número de métricas e acurácia média	125

LISTA DE SIGLAS

3D	Tridimensional
AAAI	Associação Americana de Inteligência Artificial
AR	<i>Auto Regression</i> (Auto Regressão)
CC	<i>Cepstrum Coefficients</i> (coeficientes mel-cepstrais)
cm	Centímetro
DB	Database (Banco de Dados)
DB1	Database 1 (Banco de Dados 1)
DB2	Database 2 (Banco de Dados 2)
DB3	Database 3 (Banco de Dados 3)
DB4	Database 4 (Banco de Dados 4)
DB5	Database 5 (Banco de Dados 5)
DB6	Database 6 (Banco de Dados 6)
DB7	Database 7 (Banco de Dados 7)
DB8	Database 8 (Banco de Dados 8)
DB9	Database 9 (Banco de Dados 9)
DB10	Database 10 (Banco de Dados 10)
EMG	Eletromiografia / Eletromiográfico
sEMG	Eletromiografia de Superfície
FFLS	<i>Finger-Force Linear Sensor</i> (Sensor Linear de Força dos Dedos)
FFT	<i>Fast Fourier Transform</i> (Transformada Rápida de Fourier)
FSR	Sensores de Pressão
Hz	Hertz
IA	Inteligência Artificial
IEMG	<i>Integrated EMG</i> (EMG Integrado)
IMU	Unidade de Medidas Inercial
INSS	Instituto Nacional do Seguro Social
IP	<i>Ingress Protection</i> (Proteção de Ingresso)
kg	Quilograma
LDA	<i>Linear Discriminant Analyses</i> (Análise Discriminante Linear)
LS-SVM	<i>Least-Squares support vector machine</i>
MAV	<i>Mean Absolute Value</i>

MAVS	<i>Mean Absolute Value Slope</i> (Inclinação do Desvio Médio Absoluto) Megabyte
MB	<i>Mean of Peaks Values</i>
MPV	Potencial de ação muscular
MUAP	Conjunto de potenciais de ação muscular
MUAPT	
NINAPRO	<i>Non-Invasive Adaptive Hand Prosthetics</i> (Próteses de Mão Adaptativas Não Invasivas)
NP	<i>Number of Peaks</i>
OMS	Organização Mundial da Saúde
ONSV	Observatório Nacional de Segurança Viária
PhD	<i>Philosophy Doctor</i> (Doutor em Filosofia)
RMD	Reinervação Muscular Direcionada
RMS	<i>Root Mean Square</i>
RF	<i>Random Forest</i> (Floresta Aleatória)
RNA	Redes Neurais Artificiais
SIHSUS	Sistema de Informações Hospitalares do SUS
SSC	<i>Slope Sign Changes</i>
STD	<i>Standart Deviation</i>
USB	Universal Serial Bus (Porta Serial Universal)
WL	<i>Waveform Length</i>

SUMÁRIO

1.	INTRODUÇÃO	13
1.1.	Objetivo Geral	15
1.2.	Objetivo Específico	16
1.3.	Delimitações	16
1.4.	Estrutura do Trabalho	16
2.	REVISÃO BIBLIOGRÁFICA	18
2.1.	A Anatomia Do Braço	19
2.2.	O EMG Como Ferramenta De Controle	22
2.2.1.	A Estrutura do Sinal	26
2.3.	O Banco De Dados	28
2.3.1.	Conhecendo os Bancos de Dados	29
2.4.	Inteligência Artificial	35
2.4.1.	A História da Inteligência Artificial	36
2.4.2.	Rede Neural Artificial	38
2.4.3.	Análise Discriminante Linear	44
2.4.4.	Floresta Aleatória	49
3.	ESTADO DA ARTE	54
3.1.	Modelos e técnicas do mercado	54
3.1.1.	Arm Dynamics	54
3.1.2.	Tecnologia Mioelétrica	55
3.1.3.	Hero Arm	56
3.1.4.	LUKE Arm	58
3.2.	Sistemas Classificadores	61
3.2.1.	Projeto NINAPRO e trabalhos relacionados	61
3.3.	O Brasil E Uma Análise Social	70
4.	METODOLOGIA	72
4.1.	Escolha do Banco de Dados	72
4.1.1.	Considerações Iniciais	72
4.1.2.	Justificando a Escolha	73
4.2.	Conhecendo a base de dados	73
4.3.	Ferramentas utilizadas	83
4.4.	Modelagem, Extração de Características e Técnicas	84

4.4.1. Janelamento	85
4.5. Escolhendo Diferentes Conjuntos de Movimentos	88
4.6. Métricas de Desempenho.....	89
4.7. Estrutura dos Classificadores	90
4.7.1. O Classificador com Redes Neurais Artificiais.....	92
4.7.2. O Classificador com Análise Discriminante Linear	92
4.7.3. O Classificador com Floresta Aleatória.....	93
5. ANÁLISE DOS RESULTADOS	95
5.1. Matrizes de Confusão e Acurácia.....	95
5.1.1. Resultados das Redes Neurais Artificiais	95
5.1.2. Resultados da Análise Discriminante Linear.....	105
5.1.3. Resultados da Floresta Aleatória.....	113
5.2. Comparando os Classificadores	120
5.2.1. Comparativo das Acurácias	120
5.3. Explorando a RF	123
5.3.1. Alterando a relação teste/treino	123
5.3.2. Alterando o número de fatures	125
6. CONSIDERAÇÕES FINAIS	127
6.1. Sugestões Para Trabalhos Futuros.....	128
7. REFERÊNCIAS.....	130

1. INTRODUÇÃO

A simples ideia de conviver sem algum membro do corpo ou parte dele é um pensamento capaz de causar arrepios em qualquer pessoa e infelizmente essa é a realidade para uma boa parte da população. Em um levantamento feito no ano de 2010, pelo IBGE, há no Brasil mais de 470 mil pessoas que sofreram algum tipo de amputação (FERBA, 2017), além disso, os dados mostram que o número de novos casos vem aumentando a cada ano. Dados do Observatório Nacional de Segurança Viária (ONSV) apontam que “Somente em 2014, os acidentes no trânsito brasileiro causaram sequelas permanentes em mais de 600 mil pessoas”.

Os dados de 2011 do SIHSUS (Sistema de Informações Hospitalares do SUS) apontam que 50% das amputações realizadas pelo SUS no Brasil são originárias de doenças apresentadas pelo paciente, sendo diabetes e doenças do aparelho respiratório as principais, já outros 33% foram consequências de causas externas, como acidentes ou agressões (MINISTÉRIO DA SAÚDE, 2013). A nível global, segundo dados da Organização Mundial da Saúde (OMS), acidentes de carro são o segundo maior responsável por casos de amputação, com 20% das ocorrências, o primeiro lugar fica com a diabetes, sendo responsável por 70% dos casos (SBAC, 2018).

Observando estes dados, percebe-se que casos de amputações têm duas grandes origens: acidentes de trânsito e problemas de saúde, principalmente a diabetes. Relatórios do Ministério da Saúde e do DPVAT mostram que por mais que, desde 2015, tenha ocorrido uma redução nos números de óbitos em acidentes de trânsito, o número de internações segue em um crescente (VIAS SEGURAS, 2020). Contudo, o ponto mais alarmante se dá por conta da diabetes, de 1980 a 2014 o Brasil quadruplicou o número de pessoas com a doença e acredita-se que este número vá seguir aumentando uma vez que, em média, apenas 50% dos diabéticos têm consciência do seu diagnóstico (ISHN, 2014).

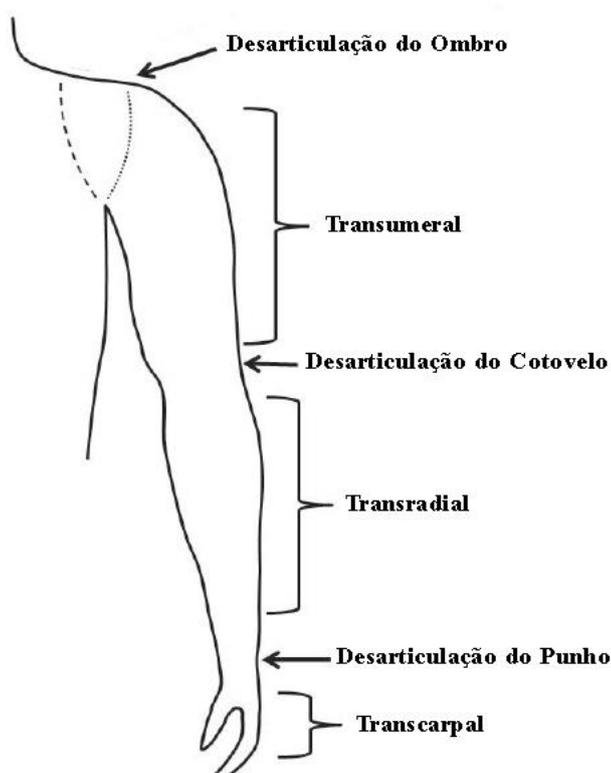
Os dados levam a crer que o número de amputações tende a aumentar no curto prazo e, portanto, cada vez mais, será necessário e indispensável desenvolver soluções que busquem auxiliar essas pessoas.

O foco deste trabalho está em auxiliar aqueles que sofreram uma amputação do membro superior, apesar de não haver dados precisos no Brasil, estima-se que 20% das amputações sejam de membros superiores. Esse tipo de amputação sofre com a

falta de opções de próteses, além disso, dadas todas as dificuldades existentes no desenvolvimento, essas próteses costumam ter um preço mais elevado e um leque de movimentos recuperados mais reduzido.

Dados os seis níveis da amputação do membro superior, que podem ser melhor visualizados na Figura 1, os mais comuns são a desarticulação parcial da mão, representando a perda de 1 ou mais dedos, seguida da amputação transradial, representando a amputação logo abaixo da articulação do cotovelo (CHUCHU AND PRITHAM, 1994).

Figura 1: Níveis de amputação de membro superior



Fonte: Adaptado de (CHUCHU AND PRITHAM, 1994)

Dentre estes níveis, há aqueles que ainda possuem a musculatura do antebraço e a capacidade de estimulá-la através de pulsos mioelétricos. Fazendo a captura destes sinais no antebraço, é possível lê-los e interpretar qual o movimento tentou-se fazer, a partir disso é possível configurar uma prótese eletrônica que replique este movimento e permita ao usuário recuperar parcial ou completamente um conjunto de movimentos.

Para a captura destes sinais de maneira tópica, pode-se utilizar sEMG (*Surface Electromyography*), também chamada de eletromiografia de superfície. Em outros casos, para uma leitura mais precisa, é necessário a inserção de eletrodos a nível intramuscular. Estes casos costumam ser apenas para situações específicas e tipicamente de estudo, ocorrendo dentro de clínicas e acompanhado de uma equipe técnica.

Para casos mais críticos, onde a amputação foi transumeral ou de toda a desarticulação do ombro, um processo a mais torna-se necessário, uma cirurgia de Reinervação Muscular Direcionada, ou RMD, consegue recuperar estes mesmos sinais, tornando possível a criação de próteses que substituam toda a porção perdida do braço.

1.1. Objetivo Geral

Este trabalho encaixa-se dentro de um grande projeto que busca desenvolver próteses para pessoas que sofreram amputações. Através da captura, filtragem, tratamento e uma boa decodificação, é possível interpretar o movimento desejado e, comunicando-se com um *hardware* propício, reproduzir esse movimento em uma prótese.

Existem muitos pontos críticos quando se trata de desenvolver um sistema capaz de fazer todo esse processo com alto grau de confiabilidade. Os sensores devem ser precisos e confiáveis para fornecer o melhor sinal possível, as técnicas de leitura e interpretação também devem ser precisas e rápidas o suficiente para melhor conforto do usuário e, por último, a prótese precisa ser capaz de reproduzir os movimentos lidos com confiabilidade e possuir maneiras de retornar um *feedback* ao usuário, uma vez que o tato perdido é parte crucial de manuseios mais delicados.

O foco do trabalho estará na evolução e aprimoramento da prótese, focando em analisar como diferentes técnicas de inteligência artificial podem se mostrar mais ou menos eficazes para a classificação.

Esse sistema deve ser confiável e robusto, porém, deve possuir um grau de simplicidade que permita ser processado e classificado rapidamente, e que assim, no futuro, possa ser integrado a todo o conjunto de uma prótese.

1.2. Objetivo Específico

- (a) Comparar as diferentes técnicas de Inteligência Artificial quanto as suas acurácias, para encontrar qual traz os melhores resultados para a interpretação do sEMG;
- (b) Implementar uma Rede Neural Artificial, uma Análise Discriminante Linear e Floresta Aleatória capazes de classificar os sinais do sEMG;
- (c) Validar as implementações através de um *dataset*;
- (d) Comparar os resultados;
- (e) Encontrar um ponto ótimo quanto as definições dos classificadores e definição dos parâmetros calculados;

1.3. Delimitações

O escopo deste trabalho limita-se a testar e aprimorar as diferentes técnicas de inteligência artificial aplicadas a leitura e interpretação de sinais eletromiográficos. As demais funcionalidades do sistema (captura dos sinais, controle da prótese e desenvolvimento da prótese mecatrônica) não fazem parte do escopo desse trabalho.

1.4. Estrutura do Trabalho

Logo a seguir, no capítulo 2, é trabalhado todo o referencial bibliográfico utilizado para dar base aos classificadores desenvolvidos. O capítulo traz uma breve explicação da anatomia do braço e como se forma o sinal EMG. Uma explicação de como se estrutura o banco de dados e que informações há nele, além de criar uma base para o entendimento do funcionamento das três diferentes técnicas de inteligência artificial que são utilizadas nos classificadores.

O capítulo 3 apresenta o que há hoje dentro no estado da arte, tanto quanto a soluções de próteses, quanto de sistemas classificadores de sEMG. No capítulo 4 é apresentada a metodologia utilizada na elaboração dos classificadores. É apresentada a justificativa da escolha do banco de dados utilizado, um estudo mais aprofundado dos sinais sEMG é feito e, por fim, aborda em detalhes a construção dos sistemas classificadores.

No capítulo 5 são apresentados os resultados obtidos, junto a algumas análises e estudos buscando aprofundar o entendimento. Encerrando, o capítulo 6 traz as considerações finais quanto ao trabalho e resume os resultados obtidos ao longo do desenvolvimento.

2. REVISÃO BIBLIOGRÁFICA

Este trabalho busca continuar o projeto já iniciado pelo aluno MIROVSKI (2018) no seu trabalho de conclusão de curso. Em seu desenvolvimento, Jonas utilizou a base de dados da NINAPRO, optando pelo *Dataset 1*, pois considerou haver muitas discrepâncias entre este e os demais bancos de dados, tanto em relação a qualidade do *hardware* de captura quanto a quantidade de dados. Ainda realizou alguns ajustes matemáticos no banco de dados, permitindo assim uma maior normalização dos dados e também os organizou da forma que julgou ser a melhor para os seus objetivos. Para a classificação, optou por utilizar RNA, uma das técnicas mais amplamente utilizadas para esse objetivo (NOVAK,2014).

Jonas desenvolveu o código em Python e o embarcou em um Raspberry Pi MIROVSKI (2018). Ao final do projeto, Jonas concluiu que atingiu parcialmente os objetivos iniciais. Como o código foi desenvolvido utilizando uma base de dados contendo apenas indivíduos saudáveis, esse sistema poderia ainda não estar apto para ler os sinais de um indivíduo amputado, pois são mais sutis e sujeitos a maiores variações entre indivíduos. Outra ressalva que levantou é o fato desses sinais terem sido capturados por profissionais e em ambiente favorável, sempre sob as mesmas condições e horário do dia (MIROVSKI,2018).

O autor relata que ocorreram alguns erros de leitura, o que reduziu um pouco a sua taxa de acertos. Entretanto, ressaltou que o sistema se mostrou muito eficiente em identificar os momentos de repouso e também apresentou uma velocidade de classificação e resposta completamente dentro do desejado para uma boa experiência do usuário.

Portanto, o projeto mostrou-se um excelente primeiro passo para um classificador de sinais de EMG embarcado, deixando como desafio para futuros projetos o refinamento do sistema classificador e técnicas para deixar o sistema apto a classificar sinais de uma pessoa amputada e em condições do dia a dia

Como forma de estabelecer uma base teórica a essa nova etapa do projeto, esse capítulo traz os conhecimentos teóricos e práticos que servem como base para o seu desenvolvimento. O sucesso da classificação parte de entender de onde se originam os sinais mioelétricos e é, justamente, o primeiro assunto abordado no capítulo. Essa parte traz a análise da anatomia musculoesquelética, como se originam os pulsos elétricos na musculatura e qual é a estrutura básica de um sinal sEMG.

Na sequência, é estudado de maneira mais aprofundada a leitura em si do EMG, bem como seus desafios, principais técnicas e ferramentas. Além disso, quais os resultados já foram obtidos por outros trabalhos e quais as dificuldades que podem surgir ao se tratar os dados.

Com isso, é feita uma análise do banco de dados escolhido para o projeto, o NINAPRO. É abordado de maneira mais detalhada como ele se subdivide, quais ferramentas de captura utiliza e como seus dados são validados. Algumas das principais *features* a serem utilizadas no classificador também são vistas.

Como este projeto é feito utilizando inteligências artificiais em Python, é necessário saber como estas funcionam, quais as especificidades de cada técnica de IA e como refiná-las para atingir um melhor resultado. Esse capítulo encerra com um breve estudo da história da inteligência artificial e como funcionam as três técnicas escolhidas para desenvolver os classificadores.

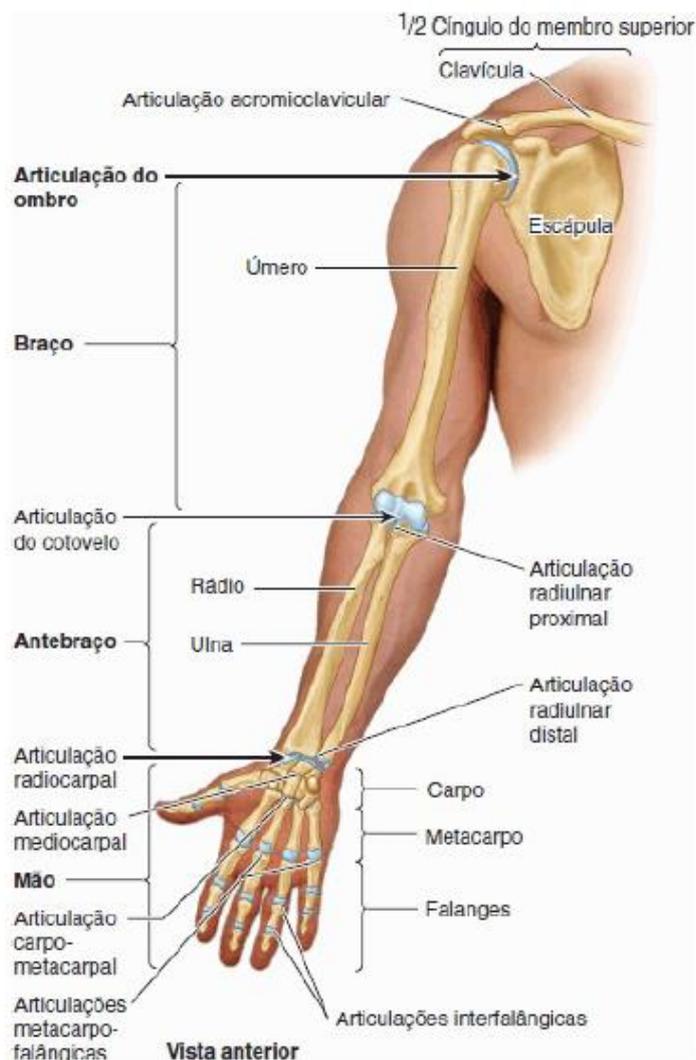
2.1. A Anatomia Do Braço

Para iniciar o desenvolvimento da prótese é importante ter um conhecimento mais aprofundado de todo o braço, ou, falando em termos mais técnicos, do membro superior. É de extrema importância saber mais sobre as relações musculoesqueléticas e como elas afetam todos os movimentos.

Popularmente costuma-se chamar de braço toda a porção do ombro até a ponta dos dedos, entretanto, essa é uma definição errada dentro dos meios técnicos. O que chamamos de braço é na verdade o membro superior, sendo que este, por sua vez, pode ser dividido em 4 partes, uma delas sendo o braço. Portanto, optando-se por respeitar a nomenclatura técnica, irá sempre ser referido neste trabalho ao “braço” como membro superior.

Como pode ser melhor visualizado na Figura 2, o membro superior pode ser dividido em 4 partes constituintes, sendo elas a cintura escapular, antebraço, mão e o já citado braço.

Figura 2: Anatomia óssea do membro superior.



Fonte: Adaptado de MOORE (2014).

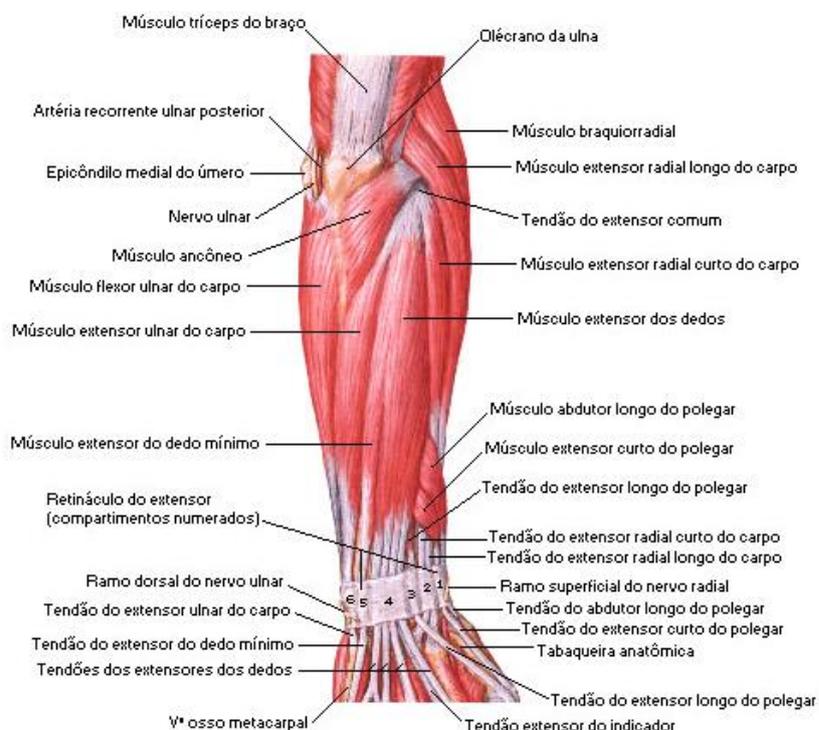
A Figura 2 permite uma boa visualização também de onde ocorrem os diferentes graus de amputação. A transcarpal ocorre com a perda de uma ou mais falanges, podendo envolver também a perda de parte do carpo ou do metacarpo. Na desarticulação de punho, a perda ocorre na articulação radiocarpal. Na transradial, ocorre entre as articulações radiocarpal e do cotovelo, havendo o corte do rádio e da ulna. Na desarticulação de cotovelo, o rádio e a ulna são completamente removidos. Nas transumeral, ocorre o corte do úmero e por fim, na desarticulação de ombro, remove-se toda a estrutura a partir da articulação acromioclavicular.

Como já citado anteriormente, quanto maior a região amputada, maior tornam-se as dificuldades, pois há a necessidade de se recuperar uma maior porção óssea, com mais músculos e complexidades de movimentos.

A musculatura dos membros superiores é uma das mais complexas do corpo humano e isso se deve ao alto grau de destreza desenvolvida ao longo de milhões de anos de evolução. Como a Figura 3 demonstra, apenas a vista anterior do antebraço possui mais de 10 músculos diferentes, além dos tendões e outras estruturas necessárias para garantir toda a precisão e amplitude de movimentos existentes.

O antebraço completo possui um total de 20 músculos, todos essenciais para que os mais minuciosos movimentos sejam possíveis. A partir deste ponto é possível perceber uma das grandes dificuldades presentes em desenvolver próteses, que é a de reproduzir, o mais fielmente possível, todos os nuances destes movimentos (NETTER, 2000).

Figura 3: Anatomia muscular da porção anterior do antebraço.



Fonte: Adaptado de NETTER (2000).

É graças aos músculos que ocorre o movimento do corpo humano, os seus tecidos são capazes de se contrair ou relaxar de acordo com os impulsos nervosos recebidos do cérebro, os quais percorrem o corpo através do sistema nervoso. Os músculos estão ligados aos tendões que por sua vez estão ligados aos ossos.

Os músculos presentes nos membros superiores são os chamados músculos estriados esqueléticos, aqueles os quais são conscientemente controlados pelo corpo humano e permitem a locomoção.

As fibras musculares se assemelham a pequenos capacitores, possuindo uma polarização natural, condição decorrente dos minerais ali presentes e de suas estruturas morfológicas. Quando o cérebro envia um pulso elétrico através do sistema nervoso, esse pulso é capaz de inverter a polarização do músculo e, essa inversão, o leva a contrair. A diferença de potencial entre o interior da célula muscular e o exterior é de aproximadamente 90 mV, sendo a parte interna com tensão negativa em relação a externa. Esse movimento conjunto, de relaxamento e contração das diversas fibras musculares, recebe o nome técnico de “potencial de ação muscular” (MUAP) (RODRÍGUEZ-CARREÑO, 2012).

Esses ciclos de contração e relaxamento podem durar apenas alguns milissegundos, a curva de força pode algumas vezes ser mais linear e, em outras, exponencial. Cada movimento requisita diferentes fibras musculares e em diferentes estantes, fazendo com que mesmo os mais simples dos movimentos parecem obras de uma complexa e perfeita engenharia, fator que torna a leitura e interpretação do EMG ainda mais complexa e única.

Os detalhes e minúcias da relação entre cada músculo e cada movimento é um assunto que poderia se estender por dezenas de páginas e acabaria fugindo do foco deste trabalho. O mais importante está em entender, dentre os diferentes movimentos, quais os mais importantes para o dia a dia, como identificá-los e classificá-los e, mais do que isso, como levar isso até uma prótese.

2.2. O EMG Como Ferramenta De Controle

O EMG ou eletromiografia é o processo de captura dos sinais elétricos que chegam ao músculo através do sistema nervoso. Esses sinais se originam no cérebro e, quando chegam ao músculo, o levam a sua contração, como já descrito na seção

anterior. Esses sinais podem ser obtidos de maneira invasiva, com pequenas agulhas contendo os sensores, ou de maneira não invasiva, com sensores sobre a pele.

Quando se opta pelo método invasivo, a leitura dos sinais torna-se muito mais confiável e com poucas interferências, dado o fato destas agulhas estarem posicionadas de forma intramuscular. Esse tipo de captura ocorre usualmente em laboratórios e acompanhado de uma equipe capacitada, a busca por sinais mais precisos geralmente está associada a estudos e pesquisas. Porém, quando se pensa em um uso diário e contínuo, seria bem pouco prático e seguro necessitar de agulhas intramusculares para que uma prótese funcione, sem falar na sua fragilidade, podendo quebrar-se com certa facilidade, mesmo no momento da inserção.

Para o método não invasivo, utiliza-se sensores posicionados na superfície da pele. Este método é chamado de eletromiografia de superfície ou sEMG. Para o sEMG, posicionam-se três eletrodos, sendo dois os chamados eletrodos de sinal, posicionados sobre o músculo, e o terceiro, chamado de eletrodo de referência, que fica posicionado sobre o osso.

O antebraço, como já visto, possui 20 músculos, tentar a captura dos sinais de cada músculo individualmente tornaria necessário utilizar 60 eletrodos. Claro que isso seria inviável, não só devido à grande quantidade de eletrodos requisitada, mas pela falta de espaço físico para o posicionamento deles. Porém, a grande proximidade entre os músculos permite que números consideravelmente menores de eletrodos já consigam fazer a leitura e trazer bons resultados. O conjunto de dados que será utilizado nesse trabalho utiliza, por exemplo, apenas 10 eletrodos, já permitindo uma elevada precisão nos processamentos dos dados.

Essa segunda técnica, apesar de possuir a vantagem de não ser invasiva, acaba sofrendo com algumas variáveis que podem afetar a leitura dos sinais, exigindo pequenos cuidados. São alguns os elementos que podem afetar o resultado da leitura, como, por exemplo, o tamanho dos eletrodos e sua localização, o tamanho dos músculos assim como a quantidade de gordura presente entre pele e músculo, o que pode alterar a distância entre o músculo e o eletrodo. A interferência de sinais de outros músculos e a interferência de ruído eletromagnético no ambiente também são alguns dos problemas desse tipo de leitura.

Cada pessoa é única, seus músculos mais fortes mudam, a intensidade dos sinais mioelétricos muda, os percentuais de gordura e características dérmicas também mudam, levando a uma assinatura única na maneira com que o corpo movimenta os

músculos. Semelhante às impressões digitais, cada pessoa terá sua maneira única de se movimentar e de como os sinais serão enviados ao músculos, isso acrescenta uma camada a mais na complexidade das classificações e mostra um dos motivos para as próteses mais avançadas, descritas no Capítulo 3, necessitarem de alguns dias ou semanas para que haja o correto treinamento do sistema classificador, pois apesar do código ser único, ele ainda deve ser treinado para o indivíduo. (ATZORI, 2012)

Para que haja uma boa resposta dos algoritmos de classificação dos sinais, é muito importante ocorrer uma etapa prévia de filtragem e extração dos pontos mais relevantes. Havendo em mãos o sinal devidamente tratado, podem ser calculadas diversas informações que são abordadas na sequência. Estes dados obtidos e transformados são utilizados como os *inputs* para o algoritmo desenvolvido, na maioria dos casos, torna-se indispensável uma etapa de treinamento e refinamento diretamente com quem irá receber a prótese, garantindo um sistema mais adaptado às especificidades do usuário.

Tendo por base o trabalho desenvolvido por Freixo (2015) em sua dissertação de mestrado, a Tabela 1 mostra algumas das características que podem ser extraídas do sinal sEMG.

Tabela 1: Características que podem ser extraídas através do sEMG dos movimentos de punho, mão e dedos

Acrônimo	Nome	Equação
MAV	Média dos valores absolutos	$MAV = \frac{1}{N} \sum_{i=1}^N x_i $
LogDet	Detector Logarítmico	$LogDet = \exp\left(\frac{1}{N} \sum_{i=1}^N \log_e(x_i)\right)$
MedAV	Mediana dos valores absolutos	$MedAV = median_i x_i $
VAR	Variância	$VAR = \frac{1}{N-1} \sum_{i=1}^N x_i^2$
MADV	Média dos valores das diferenças absolutas	$MADV = \frac{1}{N-1} \sum_{i=1}^{N-1} \Delta_i$
ZC	Cruzamentos por zero	Número de cruzamentos por zero.

NT	Número de inversões	Número de inversões do sinal da inclinação.
WAMP	Amplitude de Wilson	$WAMP = \sum_{i=1}^{N-1} \psi(\Delta_i)$
Fmean	Frequência média	$Fmean = \left(\sum_{b=1}^M fbPb \right) / \left(\sum_{b=1}^M Pb \right)$
PKF	Pico de frequência	$PKF = argmax_{fb} Pb$
VCF	Variância da frequência central	$VCF = \frac{1}{Fmean} \sum_{b=1}^M (Pb - fc)^2$
Ahist_j	Histograma de amplitude	A amplitude é dividida em N janelas. Cada Ahist _j , com 1 ≤ J ≤ N, representa o número de vezes que a amplitude caiu na janela J.
Fhist_j	Histograma de frequência	A frequência é dividida em N janelas. Cada Fhist _j , com 1 ≤ J ≤ N, representa o % de energia na janela J
Ar_r	Coeficientes autorregressivos	$x_i = \sum_{r=1}^4 AR_r x_{i-r} + \epsilon_i$
CC_r	Coeficientes cepstrais	$CC_r = -AR_r - \sum_{n=1}^{r-1} \left(1 - \frac{n}{r} \right) AR_n CC_{r-n}$
Q_j	Quantis	Q _j , com J=10, 20,90, é a frequência que marca o limite superior do menor J% do espectro de potência
EnWC_j	Energia dos coeficientes wavelet	O sinal é decomposto pela transformada discreta wavelet em 7 níveis. O % de energia de cada banda é usado como característica
ZCWC_j	ZC dos coeficientes wavelet	O ZC de cada banda é usado como característica

MAVWC_j	MAV dos coeficientes wavelet	O MAV de cada banda é usado como característica
EnWP_j	Energia do coeficiente do pacote wavelet	O sinal é decomposto pela transformada discreta de pacotes wavelet em 3 níveis. O % de energia de cada banda é utilizado como característica.

Fonte: Adaptado de (FREIXO, 2015)

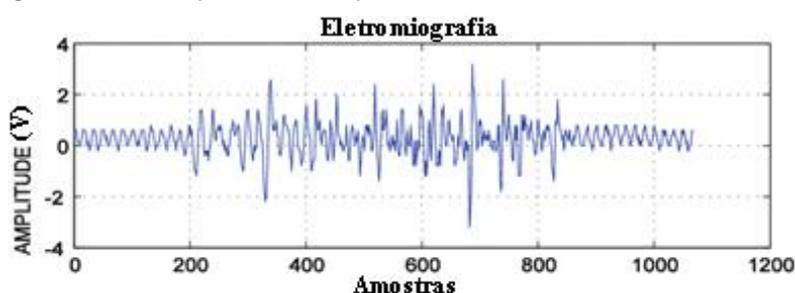
Nem todos os sinais presentes na Tabela 1 acabaram sendo utilizados nos classificadores desenvolvidos, mais detalhes sobre isso são dados no capítulo 4.

Todos estes sinais extraídos são puramente matemáticos. Quando se pensa em um sistema capaz de classificar e ler os sinais em tempo real, a realização de todos estes cálculos torna-se inviável. Portanto, é necessário buscar quais os dados mostraram-se mais relevantes e quais poderiam ser omitidos em busca não só do melhor resultado, mas também do melhor desempenho.

2.2.1. A Estrutura do Sinal

O sinal capturado é o somatório das ondas geradas por diversas fibras musculares, e possui a aparência justamente de um somatório de ondas. Quando o processo de captura é feito de forma ideal, minimizando os ruídos que possam vir a ocorrer e fazendo a correta filtragem, a aparência do EMG será semelhante à Figura 4.

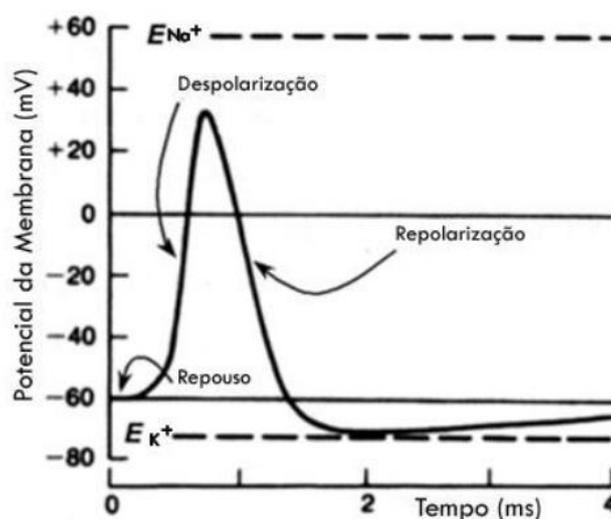
Figura 4: Sinal capturado e amplificado do EMG de um dedo do meio.



Fonte: Adaptado de (VAZQUEZ, OUBRAM, BASSAM, 2018)

Em média, o músculo em repouso possui uma tensão de -91 mV, chamado também de sua força eletromotriz e proveniente dos balanços de sódio e potássio, dentro e fora da membrana. O desequilíbrio desses minerais pode levar a alterações nas tensões médias e, em casos mais extremos, alterar as tensões ao ponto de gerar contrações espontâneas, essas contrações são popularmente conhecidas como câibras. Por sua vez, a contração do músculo ocorre em um intervalo de 1 a 5 milissegundos, podendo chegar a um pico de mais de 50 mV. Os aparelhos de EMG geralmente capturam sinais que são normalizados de -5 a 5 mV. (RAEZ, HUSSAIN, YASIN, 2006). A Figura 5 demonstra como a tensão varia no músculo mediante o estímulo.

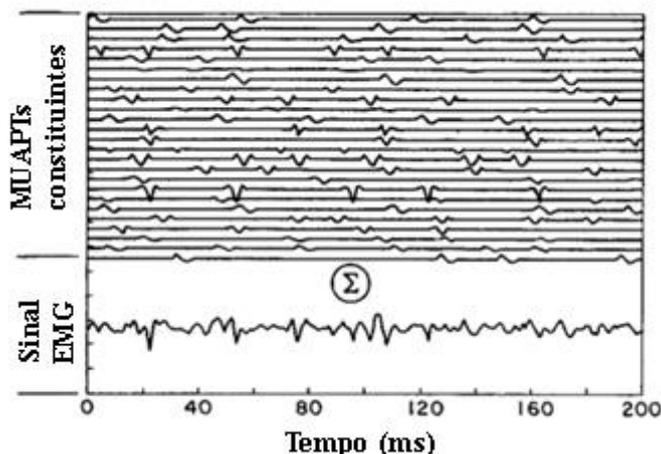
Figura 5: Variação de tensão no músculo durante sua contração



Fonte: Adaptado de (KOVÁKS, 1997)

O músculo possui neurônios motores, uma estrutura especializada de neurônios capaz de controlar uma porção de fibras de um mesmo músculo. A quantidade de neurônios motores ativada é o que determina quantas unidades motoras, ou seja, quantas fibras de um mesmo músculo serão acionadas para aquele movimento específico. Cada uma dessas unidades possui o seu próprio potencial de ação muscular, o já citado MUAP. O sinal do EMG, como já demonstrado na Figura 4, é o resultado do somatório das diferentes MUAPs desse único movimento. Em adição, a Figura 6 representa como, dentro de um único músculo, há diversos sinais vindos das diferentes fibras e que se somam para o EMG final.

Figura 6: Acima, as diferentes MUAPs capturadas em uma contração, abaixo a somatória destes sinais como visto pelo EMG.



Fonte: Adaptado de (VILLOSLADA, 2012)

O conjunto de MUAPs que formam um movimento, como visto na Figura 6, é chamado de MUAPT, algo semelhante a “conjunto de potenciais de ação muscular”, em tradução livre. A captura mais detalhada das MUAPT's constituintes só é possível com os métodos invasivos de captura, quando se opta pelos não-invasivos, apenas o sinal composto pelo somatório consegue ser lido.

2.3. O Banco De Dados

Obter os sinais mioelétricos, como visto anteriormente, pode ser feito de duas maneiras, realizar a captura utilizando métodos invasivos, onde, por mais que gerariam resultados mais completos, exigiria todo um conjunto de equipamentos avançados e uma equipe técnica para as inserções intramusculares. A segunda maneira, com captura não invasiva, também necessitaria de um *hardware* dedicado e com alta confiabilidade, além de demandar ter o conhecimento de toda a técnica para a captura. Somado a isso, seriam necessários voluntários para a captura e uma equipe que ajudaria nessa captura e organização.

Todo o processo precisa ser muito bem executado para evitar ruídos e garantir que os eletrodos estejam precisamente posicionados sobre, ou dentro, das fibras musculares desejadas. Muitos destes produtos não são baratos ou fáceis de se obter no Brasil, portanto, desejando-se trabalhar com sinais confiáveis e com grandes quantidades de amostras, optou-se por trabalhar com uma base de dados já existente, onde adotou-se o NINAPRO (*Non-Invasive Adaptive Hand Prosthetics*).

O NINAPRO consiste em um banco de dados público contendo não só sinais de EMG e sEMG, mas também alguns outros como ângulos e inclinações da mão durante os movimentos, foco dos olhos durante o movimento e muito mais. Por estarem fora do escopo deste trabalho, não são utilizados e nem abordados com maior profundidade.

Esse tipo de banco de dados tem como objetivo facilitar a pesquisa e estudos destes sinais para o desenvolvimento de próteses mioelétricas de membros superiores. O NINAPRO teve sua primeira versão em 2012, originalmente possuindo dados de 27 indivíduos realizando um total de 52 movimentos distintos. (ATZORI, 2012)

Hoje o banco de dados conta com mais conjuntos de dados, inclusive alguns contendo os sinais de captura em pacientes com amputações transradiais e aplicando diferentes instrumentos de capturas em pessoas com todo o braço. Cada conjunto de dados recebeu um número, sendo estes *Databases* numerados de NINAPRO *Database* 1 até o NINAPRO *Database* 10, além de um banco mais completo e com outros tipos de dados, o MeganePRO.

2.3.1. *Conhecendo os Bancos de Dados*

Como dito anteriormente, o NINAPRO é composto por mais de dez *Databases* diferentes, um pouco de suas diferenças técnicas é abordado nessa seção, porém não há necessidade em aprofundar o conhecimento nos bancos não utilizados. O conhecimento básico deles é apenas necessário para auxiliar na escolha de qual é o melhor para ser utilizado no projeto.

Por padrão, o NINAPRO considera 52 tipos diferentes de movimento de mão, entretanto, nem todos os *databases* utilizam a totalidade dos movimentos, alguns preferem se ater apenas ao mais simples e usuais. Os 52 diferentes movimentos podem ser vistos e melhor entendidos na Figura 7 .

Figura 7: Os 52 movimentos básicos do NINAPRO



(a) 12 posturas de mão (isométrica e isotônica)



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



(c) 9 movimentos básicos de pulso



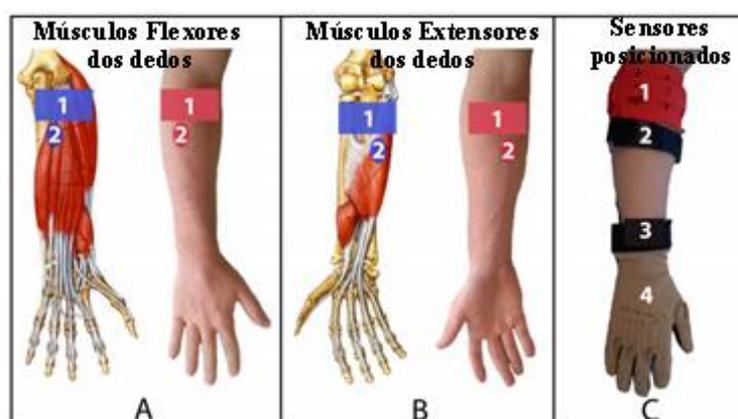
(d) 23 movimentos funcionais

Fonte: Adaptado de ATZORI (2012).

O *Database 1*, também conhecido como DB1, foi o primeiro conjunto de dados a estar disponível no NINAPRO, foi muito aprofundado por uma série de pesquisadores, suas especificidades foram melhor descritas por Atzori em sua publicação “*Building the NINAPRO Database: A Resource for the Biorobotics Community*”, ou “Construindo a base de dados NINAPRO: Um recurso para a comunidade de biorrobótica”, em tradução livre.

As fundações criadas pelo DB1 também ajudaram a alicerçar todos os futuros bancos de dados. Os 52 movimentos básicos representam muito bem a amplitude de movimentos que a mão biológica exerce no dia a dia e todas as técnicas de captura foram minuciosas. Neste primeiro conjunto, os 27 voluntários eram pessoas não amputadas, que tiveram os sensores posicionados em seu braço direito, conforme pode ser visualizado na Figura 8, além disso, utilizaram um aparelho chamado *Cyberglove II*, recurso que permite analisar e armazenar o posicionado dos dedos, este aparelho é muito utilizado na indústria da realidade virtual além de testes clínicos.

Figura 8: Posicionamento dos equipamentos de captura para o DB1: A. Posicionamento dos eletrodos para a captura dos músculos extensores dos dedos (A.1. Sensores igualmente espaçados; A.2. Sensores reserva); B. Eletrodos para a captura dos músculos flexores dos dedos (B.1. Sensores igualmente espaçados; B.2. Sensores reserva); C. Aparência do antebraço com todos os sensores posicionados (C.1. Sensores principais igualmente espaçados; C.2. Sensores reserva; C.3. Inclinômetro; C.4. *Cyberglove II*);



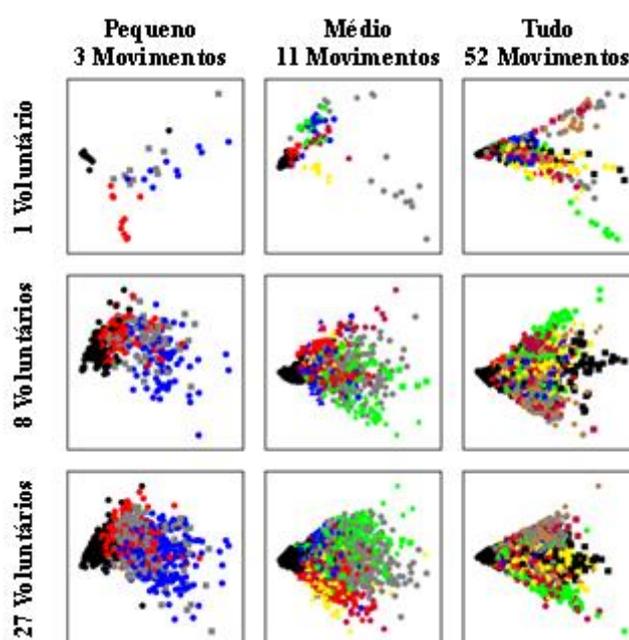
Fonte: adaptado de ATZORI (2012).

Os voluntários foram posicionados em uma cadeira confortável, de frente para uma televisão que mostrava pequenos trechos de vídeo com o movimento a ser feito. Algumas rodadas de teste foram feitas inicialmente, para garantir a familiaridade de todos com os movimentos, posteriormente, cada um dos 52 movimentos foi executado, em sequência aleatória, 10 vezes para cada um dos 27 voluntários. Incluindo os treinamentos e pausas, as capturas levaram em torno de 100 minutos para cada voluntário.

Dentre as conclusões obtidas por esse estudo, ressalta-se a fácil visualização das diferenças nos sinais entre os indivíduos. Quando analisando poucos movimentos de um único indivíduo, fica relativamente claro e fácil distinguí-los, na Figura 9 é possível observar como inicialmente, com 1 pessoa e 3 posturas de mão, os movimentos mostram-se bem distintos e fáceis de identificar. Conforme adicionam-se

mais pessoas, perde-se a distinção mais clara, inclusive havendo sobreposições de sinais em alguns pontos. Aumentar o número de posições e pessoas simultaneamente também reforça a constatação onde há uma assinatura mioelétrica única para cada indivíduo. Na Figura 9, é feita uma Análise do Componente Principal (PCA), onde os eixos representam as amplitudes dos dois principais componentes do movimento (ATZORI, 2012)

Figura 9: Comparação dos dados utilizando PCA, conforme aumentam-se o número de voluntários e de posturas analisadas. Diferentes cores representam diferentes posturas.



Fonte: adaptado de ATZORI (2012).

Realizando alguns testes e utilizando uma técnica de aprendizado de máquina chamado Máquinas de Vetores de Suporte de Mínimos Quadrados, o grupo chegou a uma margem de erro de $7,5 \pm 7,2\%$ para classificações com menos movimentos e $20,3 \pm 6,9\%$ utilizando todos os 52. O interesse com esses testes foi validar o banco de dados como confiável, permitindo ser utilizado em futuros testes por outros pesquisadores, tendo em vista que os resultados obtidos condizem com os resultados médios obtidos por outros pesquisadores ao utilizar essa mesma técnica.

Em relação ao DB2, ele foi desenvolvido por vários dos pesquisadores já presentes no DB1, os detalhes deste segundo conjunto são abordados e explicados no trabalho de Arjan Gijssberts. Neste segundo conjunto, trabalhou-se com 40 voluntários,

não amputados e realizando apenas 6 repetições. O conjunto eletrônico utilizado também foi diferente, com um novo modelo capturando 40 movimentos diferentes na altura do antebraço e mais 9 movimentos de força, buscando observar como a intensidade de força executada pelo usuário afeta o sinal do EMG. Esse, assim como todos os outros DBs do NINAPRO, foi testado com algum algoritmo simples de aprendizado de máquina buscando validar a qualidade dos dados.

Agora com voluntários que sofreram amputações transradiais, o DB3 traz uma ótica mais realista para o projeto, afinal, essas são as pessoas que realmente precisam das próteses. Apenas 11 pessoas participaram deste banco de dados, além disso, alguns problemas foram encontrados, como nem todos conseguirem terminar os testes devido a fadiga ou dor, e ao fato de nem todos terem uma espessura de antebraço grande o suficiente para posicionar todos os eletrodos necessários.

Os voluntários, todos homens com idade média de 42 anos, responderam uma série de questionários, incluindo sobre sentirem quadros de membro fantasma e até dor no membro fantasma. Posteriormente, foram posicionados em frente a um monitor com os devidos sensores já posicionados. As imagens com os movimentos a serem feitos eram mostradas aos voluntários, foi pedido para que “reproduzissem” aqueles gestos da maneira que mais lhes parecesse natural. Semelhante ao DB2, foram utilizados 40 padrões de movimentos e mais 9 padrões de força.

A classificação desse tipo de sinal é muito mais complexa, primeiramente pela intensidade do sinal ser muito menor e por não haver uma confirmação sobre a relação estímulo-movimento. Na fase de validação, o banco de dados obteve uma média de 46% acertos utilizando apenas os parâmetros RMS do sinal (ATZORI, 2014).

Esse teste também demonstra algumas conclusões interessantes que relacionam a acurácia da classificação com as características dos voluntários. Quanto maiores as sensações de membro fantasma relatados, maior a acurácia de classificação. Da mesma forma, quando maior o percentual remanescente do antebraço, maior a acurácia. De forma contra intuitiva, quando mais anos se passaram desde a amputação, melhor foi a acurácia na classificação dos movimentos.

Abordando os *databases* restantes de maneira mais sucinta, o DB4 traz 10 voluntários não amputados. A captura foi feita com eletrodos do tipo “cometa”, utilizando os mesmos princípios dos testes anteriores. A captura ocorreu com todos os 52 movimentos demonstrados na Figura 7. O DB5 foi produzido simultaneamente ao DB4, utilizando outros 10 voluntários, a mesma técnica e base de movimentos foram

escolhidos, sendo a única mudança o *hardware* de captura, aqui, utilizou-se duas braçadeiras da Thalmic Labs, chamadas Myo Armbands.

Figura 10: Demonstração da Thalmic Myo Armband, com seus 8 canais de captura e movimentos que garante identificar.



Fonte: adaptado de (TATARIAN, 2018)

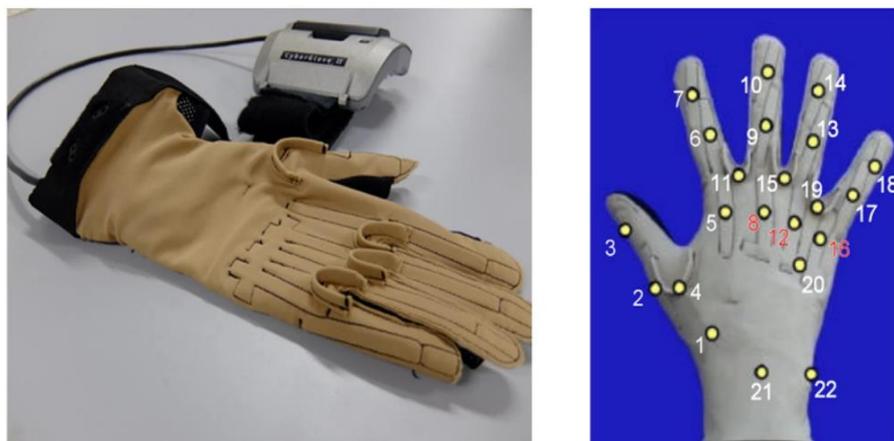
No DB6, um grupo de 10 indivíduos repetiu os mesmos movimentos, duas vezes ao dia por durante 5 dias. Esse estudo buscou analisar como diferentes horas do dia ou mesmo diferentes dias podem afetar os sinais de um mesmo indivíduo. No DB7, 20 indivíduos não amputados e 2 com amputações transradiais participaram da captura de dados.

Com uma finalidade mais específica, o DB8 tem como intenção ser usado para próteses que buscam recuperar apenas o movimento dos dedos e não do punho todo. O banco utiliza os dados de 10 voluntários não amputados e 2 com amputações.

O DB9, maior de todos com relação ao número de voluntários, conta com 77 indivíduos não amputados, os dados foram adquiridos através do *hardware* Cyberglove II e contaram com 40 movimentos.

Mais recente dentre todos, o DB10 é também chamado de MeganePro, uma base de dados multimodal de voluntário amputados e não amputados, trazendo dados de EMG, inercial, rastreamento ocular, visual, comportamental e clínico. Uma das ferramentas de captura é a *Cyberglove II*, que pode ser vista na Figura 11.

Figura 11: O Cyberglove II e a posição dos seus sensores



Fonte: Adaptado de (JARQUE-BOU, ATZORI, MÜLLER, 2020)

A intenção desse banco é fornecer uma vasta quantidade de dados para o desenvolvimento de inteligências capazes de uma decodificação completa, utilizando muito mais do que apenas o EMG como base. O MeganePro, por sua vez, já possui 4 *datasets* dentro do seu escopo, todos do ano de 2020.

2.4. Inteligência Artificial

Inteligência artificial (IA) é o nome dado para uma demonstração de inteligência vinda de uma máquina ou programa. Esse tipo de tecnologia permeia o imaginário humano há séculos, entretanto, apenas os avanços computacionais dos últimos 100 anos é que permitiram que começasse a dar os seus primeiros passos fora desse imaginário. Em especial, os últimos anos foram marcados por uma imensa evolução, não só do poder de processamento disponível, mas também do seu custo cada vez mais acessível. Essa facilidade levou a uma explosão de novas técnicas e experimentos sendo criados por qualquer um interessado no assunto. Existem hoje, diversos tipos de inteligência artificial no mercado, evoluídas a ponto de serem especialistas em alguma modalidade, fazendo com que para cada problema, haja uma IA dedicada para sua resolução.

Segundo Bruce G. Buchanan, em tradução livre, “A história da inteligência artificial é uma história de fantasias, possibilidades, demonstrações e promessas”. O que Bruce quis dizer com essa frase, é que o conceito de haver uma inteligência artificial, e que ao mesmo tempo está sob o controle humano, é algo que já pode ser

observado no imaginário humano desde registros muito antigos. Esses pensamentos permearam contos, histórias e sonhos por séculos da história humana.

Para este projeto de sistema classificador, foram escolhidas 3 IAs sendo elas a Rede Neural Artificial (RNA), Análise Discriminante Linear (*LDA*), e Floresta Aleatória (*RF*). A escolha se deu pelo fato de serem técnicas amplamente utilizadas no mercado e com um grande poder de solucionar problemas, além disso, diferem das técnicas utilizadas por Atzori *et al* (2015) nas principais pesquisas relacionadas ao NINAPRO, podendo assim trazer um olhar mais amplo para possíveis novas alternativas. Com os testes, pretende-se chegar a uma melhor conclusão sobre qual dessas metodologias irá melhor se adequar ao objetivo do projeto.

2.4.1. A História da Inteligência Artificial

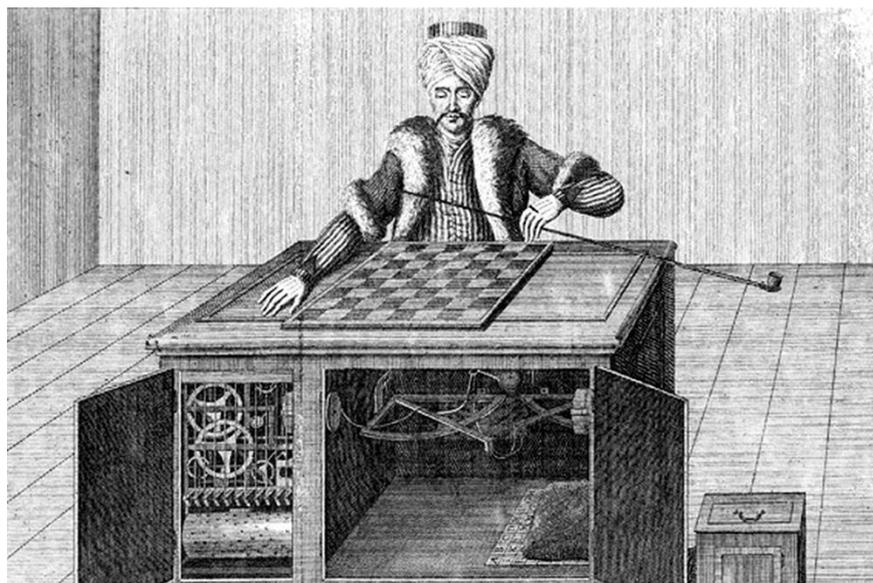
A história da inteligência artificial acompanha os seres humanos desde os seus primeiros pensadores, um dos registros mais antigos desse conceito está na *Ilíada*, de Homero, onde imaginou a existência de assistentes mecânicos, também conhecidos como autômatos. Por séculos, diversos filósofos devanearam sobre a possibilidade de máquinas inteligentes e como esses dispositivos seriam capazes de nos auxiliar na nossa própria concepção do que é ser humano. René Descartes por muitas vezes citou o conceito de “homem mecânico”, por mais que o visse de forma metafórica. Leibniz e Pascal, entretanto, viam a ideia de forma muito mais palpável, chegando a criar máquinas capazes de executar cálculos aritméticos, mecanismos estes que eventualmente tornaram-se as calculadoras.

O universo da literatura e ficção científica por séculos também utilizou destes recursos. Esses conceitos podem ser vistos em obras de Julio Verne, Isaac Asimov (conhecido por muitos como o pai dos robôs) e mesmo em obras mais fantásticas, como em *O Mágico de Oz*. A lista segue por centenas de nomes, passando por outros clássicos, como *Frankenstein* e o trompetista mecânico de Ludwig van Beethoven.

Essa busca incessante levou a criação de um dos primeiros “autômatos” da história, quando em 1770 Wolfgang von Kempelen criou o Turco Mecânico, sua aparência pode ser vista na Figura 12. Esse autômato era composto por uma enorme mesa de madeira com um tabuleiro de xadrez no centro, atrás dela, a figura de um homem turco movimentava as peças. A máquina era capaz de jogar xadrez sozinha e movimentar as peças, chegando a ganhar partidas contra grandes nomes do xadrez da

época e personalidades famosas, tais quais Napoleão Bonaparte e Benjamim Franklin. O segredo da máquina só foi descoberto em 1820, 16 anos após o falecimento de Wolfgang. Apesar da grande engenhosidade mecânica, o segredo por trás da “Inteligência” era na verdade um ser humano, escondido dentro da mesa, onde era capaz de observar o jogo e realizar os movimentos.

Figura 12: O Turco Mecânico, em desenho feito por Freiherr Joseph Friedrich zu Racknitz em 1789.



Fonte: Adaptado de (BUCHANAN, 2006)

Apesar de toda a carga histórica, o vislumbre das primeiras máquinas inteligentes só foi surgir na Segunda Guerra Mundial, com a Enigma de Alan Turing. Desde então, os computadores foram ficando cada vez menores, aumentando seu número de transistores e aumentando a capacidade de processamento de forma exponencial.

As constantes evoluções do meio levaram a criação da AAI, a Associação Americana de Inteligência Artificial, em 1980. A década de 80 também marcou o período onde os computadores começaram a adentrar os lares, permitindo que cada vez mais e mais pessoas pudessem testar e criar as suas próprias tecnologias. Este trabalho em questão é um exemplo disso, onde diferentes técnicas de inteligência artificial são aplicadas por um estudante do seu computador pessoal.

O grande acesso a poder de processamento fez com que cada vez mais, entusiastas possam, do conforto de seus lares, criar suas próprias inteligências, testá-las e melhorá-las em questões de dias ou semanas. Em especial, os últimos 10 a 15

anos tornaram-se o ápice dessa tecnologia, conceitos de inteligência artificial estão presentes nos mais diversos âmbitos da vida cotidiana, como monitorar compras no mercado e farmácia, aprender seus horários de trabalho para recomendar melhores rotas e horários ou até mesmo ajudar médicos a identificar doenças.

Aplicações de IA dentro do âmbito da saúde vem se tornando cada vez mais normal e corriqueiro. Prioridades de atendimento em hospitais, muitas vezes, são definidas através de um sistema que classifica os diferentes pacientes em espera. Leituras de eletrocardiograma podem ser feitos por um relógio no pulso ao longo do dia todo e ainda monitorar a qualidade do sono.

Prova de que mesmo um objeto conhecido há décadas pode passar a carregar funções inteligentes, recentemente os relógios adquiriram novas utilidades, um destes modelos com função de eletrocardiograma foi capaz de detectar o ataque cardíaco em um usuário com alguns dias de antecedência, esse aviso permitiu que ele procurasse um médico e pudesse tratar o possível ataque que, de fato, poderia ocorrer a qualquer instante.

Dentro do contexto hospitalar, muitas inteligências estão sendo desenvolvidas para gerar um primeiro diagnóstico, analisando eletrocardiogramas, raios-x e exames de sangue. Estes sistemas, quando bem treinados e aperfeiçoados, são capazes de obter resultados e precisões superiores ao de um ser humano. Claro que o erro ou a falha ainda podem existir (não só por parte da máquina), fazendo com que até hoje um acompanhamento humano seja indispensável.

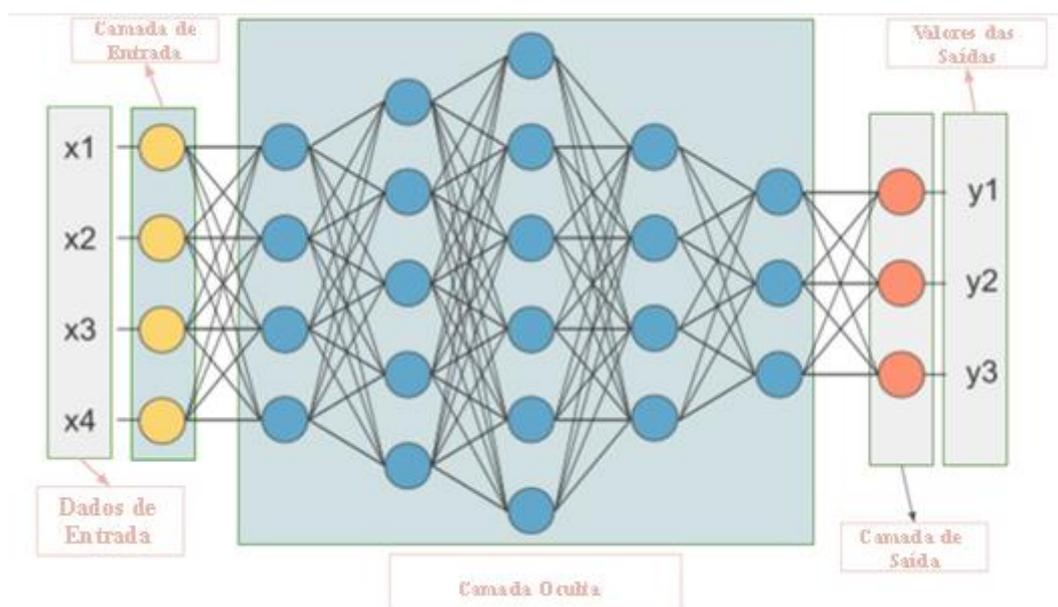
2.4.2. Rede Neural Artificial

Redes Neurais Artificiais, ou RNA, é a uma das técnicas escolhidas para ser implementada neste projeto, é também a mais popularmente utilizada dentre as três. Seu funcionamento, em síntese, consiste em simular o sistema neural humano, onde um conjunto de dados é processado por essa cadeia de neurônios, passando por um número pré-definido de camadas internas até chegar à saída, a qual pode ser um único bit ou um conjunto de bits. Esse processo precisa ser treinado com vários dados para que assim o sistema possa “aprender” como interpretá-los e descobrir quais são mais relevantes para o resultado.

A Figura 13 demonstra um pouco mais do funcionamento de uma rede neural, o conjunto de dados passa por uma primeira camada, chamada camada de

entradas. Esses dados são transmitidos para uma camada oculta, composta por um número pré-definido de subcamadas e neurônios. Nessa transmissão, o bit em um neurônio é transmitido para todos os neurônios da camada seguinte, porém há um “peso” para cada par. Esse peso é automaticamente definido pela rede conforme são feitos os treinamentos. Ao fim, essas camadas internas se comunicam com a última camada, também chamada camada de saída.

Figura 13: Exemplo de estrutura de uma Rede Neural Artificial.



Fonte: Adaptado de (ZHU, 2019)

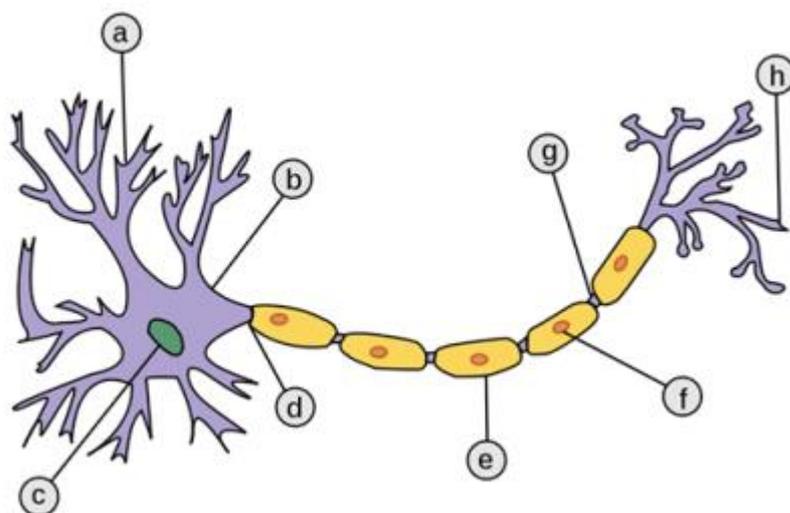
Com isso, pode-se visualizar cada saída como um conjunto de somatórios e multiplicações com pesos diferentes dos dados de entrada. É um sistema que busca ser preditivo, portanto, além de resposta positivas ou negativas, também é possível obter respostas inconclusivas, onde o conjunto de dados posto na entrada não consegue levar a nenhum resultado que a IA já tenha entendido (ZHU, 2019).

Apesar de em um primeiro momento parecer desinteressante receber respostas inconclusivas, esse resultado pode ser de grande utilidade em etapas de filtragem de elementos. Utilizando como exemplo um sistema que monitora a qualidade da solda em uma fábrica, sistema esse desenvolvido com uma RNA, recebe como entrada a foto da solda em questão, já treinado milhares de vezes com fotos de diferentes soldas, a IA sabe muito bem dizer o que está bom e o que não está para a maior parte dos casos, evitando assim que muito tempo e mão de obra sejam perdidos com inspeções, ao mesmo tempo, há uma pequena quantidade de soldas que o

sistema não consegue concluir quanto a sua qualidade, levando um operador humano a realizar a revisão. Assim, garante-se que quase todas as respostas obtidas são conclusivas e que haja o mínimo de erros, fazendo com que apenas os casos que necessitam uma atenção humana sejam levados a um responsável, tornando todo o processo mais ágil e seguro.

Ao analisar a estrutura de um neurônio, podemos entender mais sobre como a tecnologia imitou a natureza e desenvolveu uma estrutura muito eficaz para detecção de padrões. A Figura 14 mostra as partes do neurônio e nos ajuda a começar a entender um pouco mais o funcionamento da RNA.

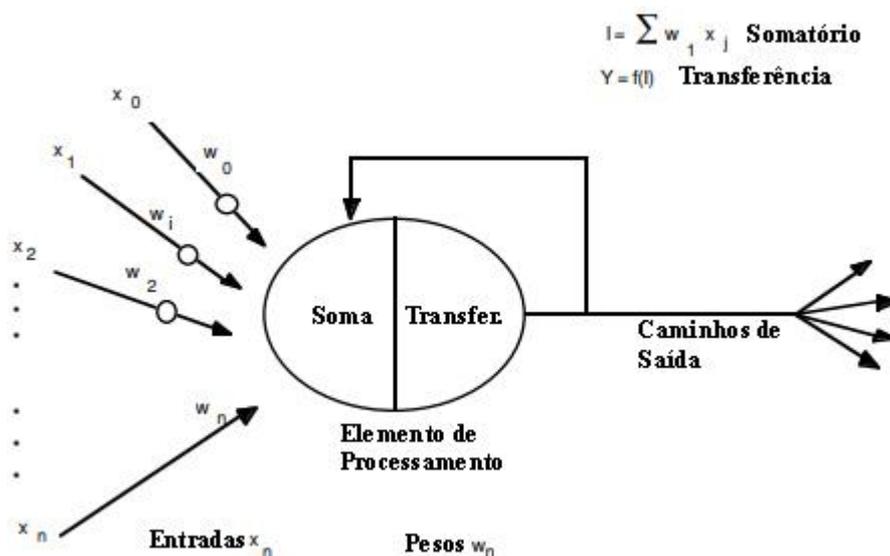
Figura 14: Estrutura de um neurônio. a. Dentrito b. Soma c. Núcleo d. Axônio e. Bainha de mielina f. Célula de Schwann g. Nódulo de Ranvier h. Axônio Terminal



Fonte: Adaptado de (MOREIRA, 2013)

Como visto na Figura 14, o neurônio possui um dentrito, essa estrutura é responsável por capturar os sinais e estímulos vindos de fora. No centro, há o núcleo e a soma, compondo o corpo celular, este ponto onde as informações são processadas e calculadas. A resultante desse “cálculo” é enviada através dos axônios para os demais neurônios e estruturas do cérebro. Na Figura 15 e 16, observa-se como isso foi transferido para o neurônio artificial.

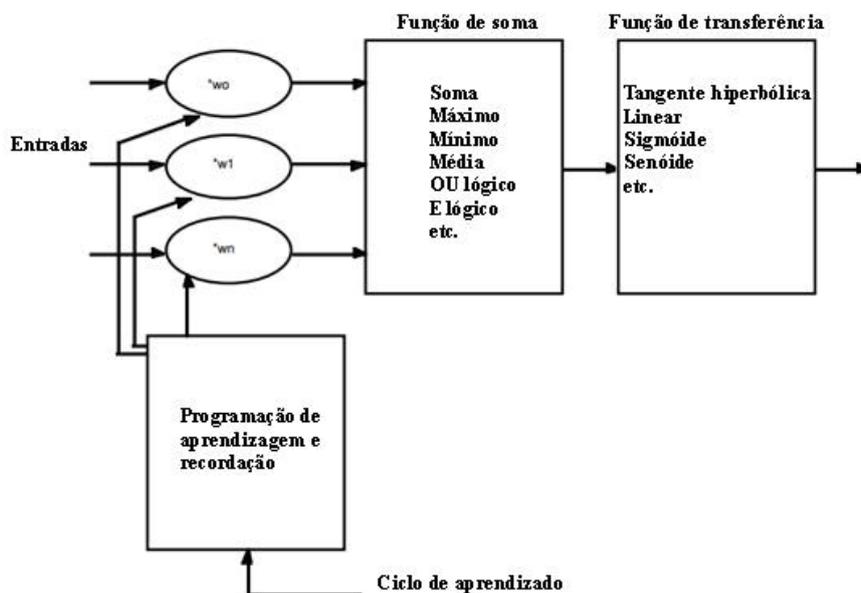
Figura 15: Estrutura do neurônio artificial



Fonte: Adaptado de (ANDERSON, 1992)

Esse neurônio artificial, como o visto na Figura 15, ajuda a trazer um maior entendimento dessa rede. As diferentes entradas, provenientes de outros neurônios anteriores ou da própria camada de entrada, são levadas a área equivalente a soma de um neurônio biológico, nessa região, todas as entradas multiplicadas pelo seu peso sofrem alguma operação matemática, podendo ser soma, subtração, média ou qualquer outra que o sistema julgar necessário para computar a saída. Em seguida, indo para a região de transferência, que pode ou não passar por mais uma função e ajustar o seu valor, posteriormente seguindo os caminhos de saída para todos os neurônios das camadas a seguir.

Figura 16: Representação em detalhes da unidade de processamento.



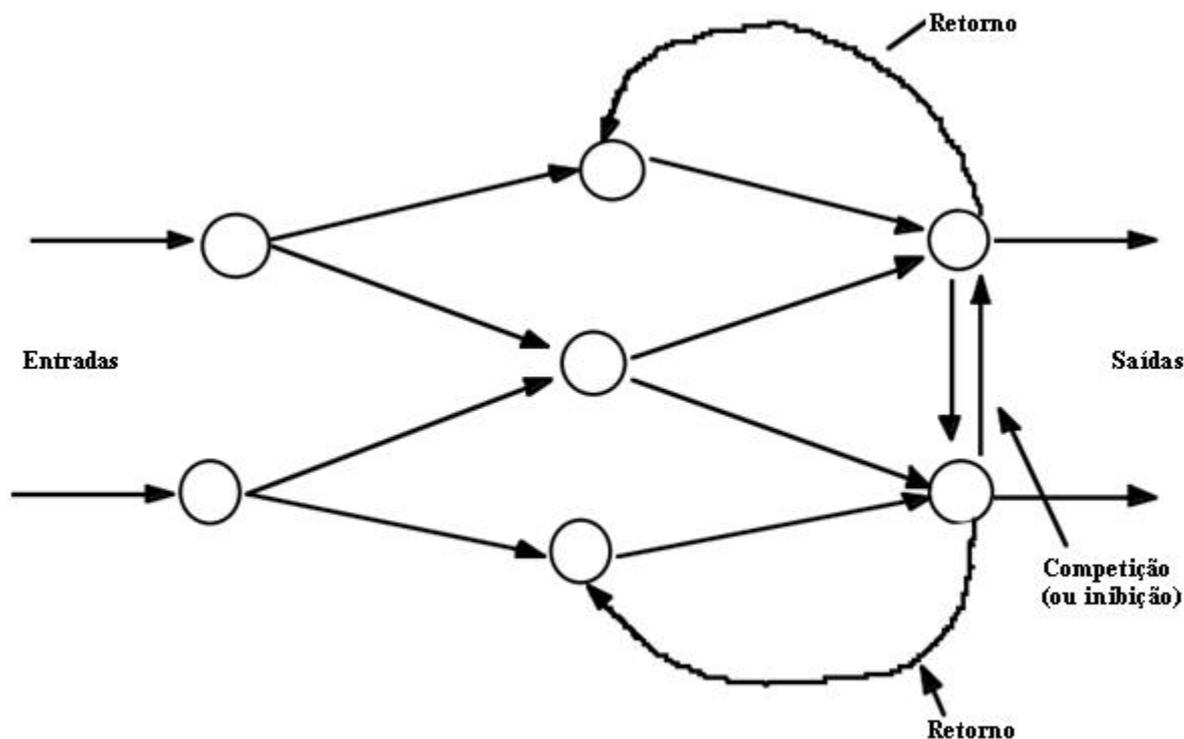
Fonte: Adaptado de (ANDERSON, 1992)

Interessantemente e, de certa forma, contra intuitivo, mais neurônios e mais níveis de camadas ocultas não necessariamente significam um melhor resultado, as redes precisam ter um tamanho adequado para seu objetivo. Possuir poucos neurônios pode levar a falhas em detectar nuances do processo, contudo, neurônios de mais podem detectar nuances que na verdade não existem e obter uma resposta com ruídos desnecessários.

Torna-se necessário também citar um possível problema do excesso de neurônios, com o termo técnico de *overfit*, esse problema acontece quando o sistema está tão bem adequado aos dados de treino que é capaz de interpretar só eles. Um “cérebro” tão especialista naquilo que já viu que não é capaz de aprender e interpretar nada novo.

Dentro da estrutura de uma RNA, ainda é possível haver algumas outras formas de troca de dados entre neurônios, formas essas demonstradas na Figura 17.

Figura 17: RNA com mecanismos de Feedback e inibição



Fonte: Adaptado de (ANDERSON, 1992)

As RNAs, apesar de geralmente possuírem a estrutura básica de um neurônio falando com todos aqueles a frente e, assim, sucessivamente até eventualmente chegar à saída, também podem conter alguns mecanismos mais “avançados”. Um deles é o de inibição lateral, também conhecido como competição, onde um neurônio tem o poder de inibir os outros neurônios de sua camada, esse tipo de mecanismo pode ser muito útil em alguns algoritmos, como por exemplo em detecção de texto, onde a possibilidade de a resposta ser um P é de 0.90 e de ser um R é de 0.70, assim é interessante ao sistema escolher a resposta de maior probabilidade e inibir todas as outras.

O segundo mecanismo é o de *feedback*, onde a resposta de uma camada pode ser jogada para uma camada anterior, esse tipo de rede possui uma estrutura dinâmica, alterando-se até atingir um ponto de equilíbrio.

Outra comparação é o fato de similarmente ao cérebro humano, as RNAs também aprenderem através da experiência. Isso é visto por muitas personalidades do mundo da ciência e tecnologia como o invento que irá permitir o mundo da computação atingir o próximo nível de sua evolução. No caso das RNAs, essa experiência é

adquirida através da etapa de treinamento, sendo que este pode ser supervisionado ou não supervisionado.

Em treinamentos supervisionados, a RNA define de maneira aleatória os pesos das ligações entre neurônios, em seguida é alimentada com diversos conjuntos de dados já com a saída desejada, permitindo que o sistema possa ir gradualmente definindo os pesos das ligações. Já nos treinamentos não supervisionados, o sistema recebe apenas as entradas, sem ter noção de quais as saídas. Essa segunda técnica é muito utilizada para tentar encontrar padrões nos dados ou mesmo ver como a máquina os separa em diferentes grupos.

A capacidade em detectar padrões das Redes Neurais Artificiais explica a sua escolha para ser utilizada neste projeto. Apesar das variações entre indivíduos em seu EMG, as redes neurais podem se mostrar um grande aliado em caracterizá-los. Além disso, seu processo de aprender através da experiência sugere que um sistema bem montado e estruturado pode aprender com o seu usuário, assim, com o passar dos tempos tornar-se ainda mais especialista em ler os sinais eletromiográficos de uma única pessoa.

2.4.3. *Análise Discriminante Linear*

O segundo tipo de classificador a ser utilizado neste trabalho é a Análise Discriminante Linear, ou LDA. É uma técnica de estatística e *machine learning* usada para reconhecimento de padrões. Alguns dos seus usos mais comuns são reconhecimento de fala, reconhecimento de imagens e pré filtragem de dados para outras inteligências artificiais (MAKLIN, 2019).

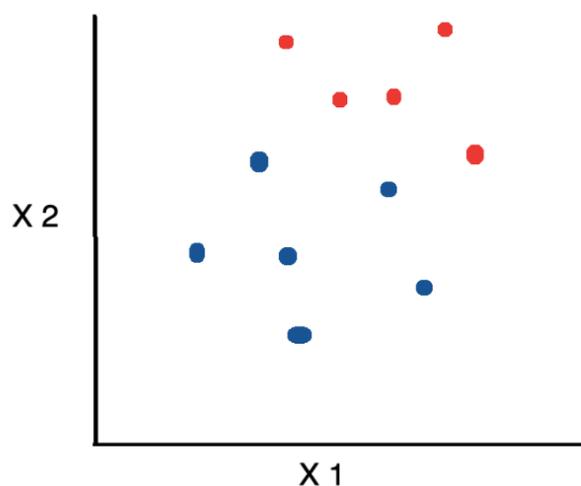
Como o nome sugere, sua aplicação consiste em pegar um conjunto de dados com n dimensões e reduzi-lo para, geralmente, 2 dimensões os separando em pequenos *clusters*, ou conjunto de dados similares. A técnica se baseia em duas máximas: Manter a maior distância possível entre os centros dos diferentes *clusters* e ao mesmo tempo ter a menor distância possível dos elementos de um *cluster* ao seu centro.

Quando se utiliza um treinamento supervisionado, ou seja, com o LDA já sabendo a qual grupo pertencem os dados na entrada, seu funcionamento será voltado para futuramente saber classificar rapidamente qualquer novo elemento. Já quando se

utiliza um treinamento não supervisionado, ou seja, apenas os dados são colocados no sistema, mas nenhuma informação sobre a que grupo pertencem, o LDA passa a ter uma nova funcionalidade, que é a de encontrar padrões nos dados e os separar em diferentes grupos.

Supondo um conjunto de dados divididos em dois grupos, representados na Figura 18 com as cores azul e vermelho, onde estes dados são bidimensionais, ou seja, são afetados apenas por duas variáveis (X_1 e X_2). O LDA utiliza o princípio de reduzir dimensões, portanto a próxima etapa é encontrar a reta ideal para linearizar a resposta (MAKLIN, 2019).

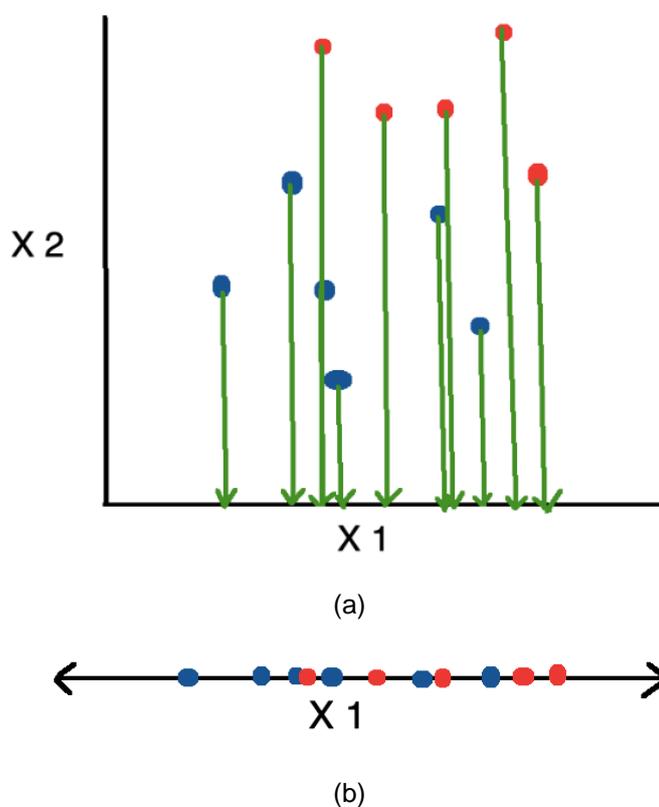
Figura 18: Exemplo de um conjunto de dados no plano cartesiano e divididos em dois grupos.



Fonte: Adaptado de (MAKLIN, 2019)

Entretanto, reduzir as dimensões apenas projetando os pontos sobre um dos eixos não irá retornar um resultado satisfatório. Isso pode ser observado na Figura 19, onde existe uma baixa distinção entre os grupos e uma enorme região central onde há a sobreposição de muitos pontos.

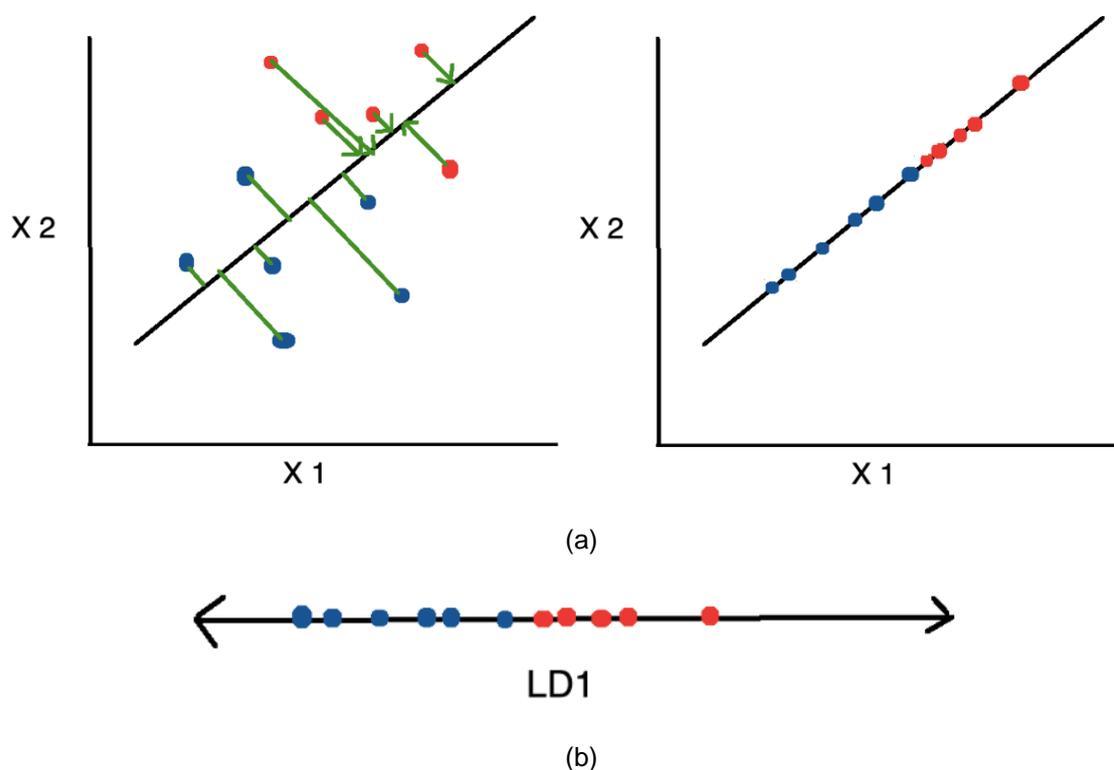
Figura 19: (a) Pontos do plano bidimensionais sendo projetados sobre o eixo X1; (b) Reta unidimensional X1 com o resultado linearizado do sistema



Fonte: Adaptado de (MAKLIN, 2019)

Justamente para evitar essas respostas, onde a maior parte dos dados está em uma zona de indefinição, surgem os dois princípios máximos dessa técnica. Definir uma reta onde o centro das zonas está o mais afastado o possível ao mesmo tempo que a distâncias dos diferentes elementos dessa zona estejam com a menor distancia média possível deste centro (MAKLIN, 2019). Aplicar o LDA corretamente sobre a estrutura de dados vista nas figuras anteriores, permite que uma reta ideal seja traçada e além disso, dentro dessa reta seja possível definir o ponto que separa os dois grupos.

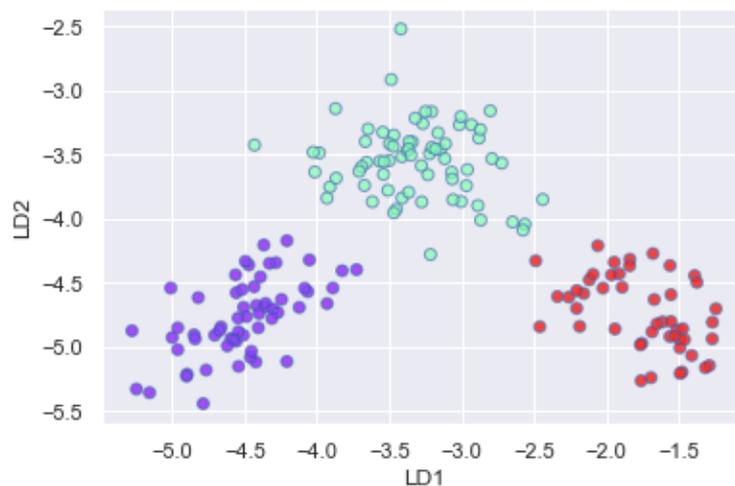
Figura 20: (a) LDA corretamente aplicado, em relação a técnica utilizada na Figura 19, e reta ideal traçada sobre o eixo; (b) Resultado do LDA, onde é possível definir claramente o ponto que separa os dois grupos



Fonte: Adaptado de (MAKLIN, 2019)

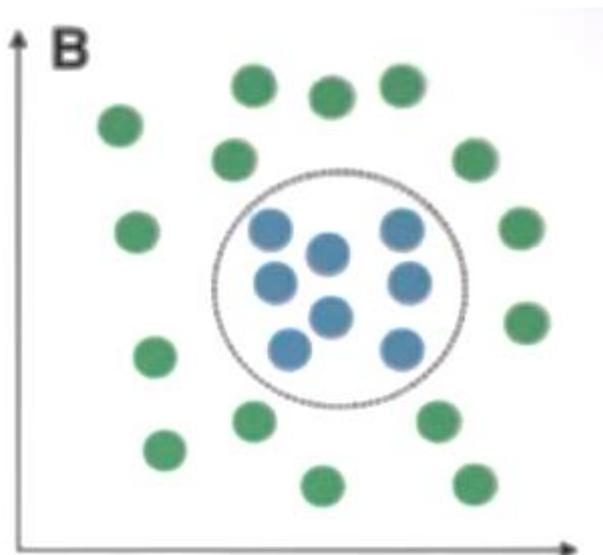
O LDA é uma técnica que pode ser aplicado em qualquer conjunto de dados, mesmo com milhares de dimensões e dezenas de grupos (MAKLIN, 2019), novamente, essa é uma das técnicas preferidas quando o assunto é detecção de padrões, tais quais letras, falas, digitais e faces. A Figura 21 mostra um exemplo de aplicação de LDA onde haviam mais de 20 dimensões de dados diferentes, todos aplicando-se a três grupos distintos, a correta execução permitiu uma excelente *clusterização* dos grupos. Já a Figura 22 traz um exemplo de conjunto de dados para o qual LDA não se aplica.

Figura 21: Aplicação de LDA contendo três diferentes grupos.



Fonte: Adaptado de (MAKLIN, 2019)

Figura 22: Exemplo de conjunto não linearizado.



Fonte: Adaptado de (MAKLIN, 2019)

Todavia, a aplicação de LDA possui uma grande restrição, ela só pode ser executada em conjuntos de dados que sejam lineares (MAKLIN, 2019). A Figura 22, por exemplo, traz um conjunto não linear de dados, fazendo assim com que a aplicação de LDA não seja capaz de extrair uma reta que isole os dois diferentes grupos. Portanto, apesar de poderosa, a LDA possui uma grande restrição quanto ao tipo de dados na qual é efetiva.

2.4.4. Floresta Aleatória

A terceira e última das três técnicas a ser abordada é a floresta aleatória, ou Random Forest (RF). Possui como base as árvores de decisões, porém, ao invés de se trabalhar com apenas uma árvore, o conceito é o de construir dezenas, centenas ou até milhares de árvores de decisões, e tal qual na vida real, o conjunto de árvores forma a floresta.

Uma única árvore de decisões possui certas limitações, ela atua como um sistema especialista e é muito eficiente em resolver os problemas ou classificar os dados com os quais ela foi projetada (BIAU, 2012), porém é muito limitada em resolver problemas que fujam um pouco dessa base, ou mesmo que contenham um caminho de solução não linear.

O fato de as árvores de decisões serem muito competentes em classificar os dados para as quais foram desenvolvidas, levou ao conceito de criarem-se um conjunto de árvores, todas treinadas para alguns aspectos de um mesmo banco de dados. Assim, o resultado poderia ser obtido a partir da somatória de todas as parciais.

Hoje, a RF é uma das técnicas mais populares de IA além de ser extremamente poderosa (BIAU, 2012), tem capacidade de funcionar tanto como sistema classificador como para aproximações lineares. Cada árvore recebe um conjunto de dados de entrada e busca por uma resposta, classificando estes dados segundo as suas ramificações. Trabalhando-se com um conjunto de árvores (floresta), obtêm-se um conjunto de respostas, as quais podem passar por uma função matemática, levando diretamente a resposta final, ou os dados podem ser levados para uma segunda floresta que enfim chegará ao resultado.

A Figura 23 demonstra o processo simplificado de uma árvore de decisão, neste caso, filtrando os dados de entrada pela cor e se estão sublinhados ou não.

Figura 23: Exemplo de estrutura de uma Árvore de Decisões



Fonte: Tony Yiu – Understanding Random Forest

O modelo de floresta aleatória possuiu um bom desempenho preditivo, isso se deve a uma característica conhecida como a sabedoria das massas. Onde diversas árvores, gerando diferentes resultados sob diferentes critérios, pode ter um desempenho muito acima da média.

As florestas aleatórias foram propostas por Leo Breiman no início dos anos 80 e tomaram forma como modelo de *Machine Learning* no início dos anos 2000, agregando pesquisas anteriores ao seu conhecimento, Breiman conseguiu demonstrar esse conceito da sabedoria das massas. Propondo que um conjunto de árvores de decisões, criadas de forma aleatória, porém condizentes com um mesmo banco de dados, teriam uma resposta mais assertiva do que outros métodos, surgindo a partir disso as florestas aleatórias.

Desde o momento de sua criação, a RF mostrou-se uma forte candidata ao estado da arte das técnicas de *Machine Learning*, posto esse que mantém até hoje. Os pontos positivos que a tornam tão querida são a fácil e ágil implementação de um sistema com alta acurácia e capacidade de administrar quantidades enormes de dados.

Louppe (2014), busca trazer um olhar mais moderno sobre as árvores de decisão. Segundo Louppe, a eficácia das florestas aleatórias foi amplamente comprovada de forma empírica, porém há poucas bases matemáticas que expliquem tamanha qualidade de resultados. Além disso, Louppe questiona alguns dos algoritmos

modernos para a construção dessas florestas, segundo ele, em tradução livre “Enquanto o processo de construção de uma única árvore de decisões pode ser facilmente descrito em meia página, implementar o algoritmo para uma floresta aleatória continua sendo uma tarefa desafiadora, envolvendo desafios que são facilmente subestimados.”

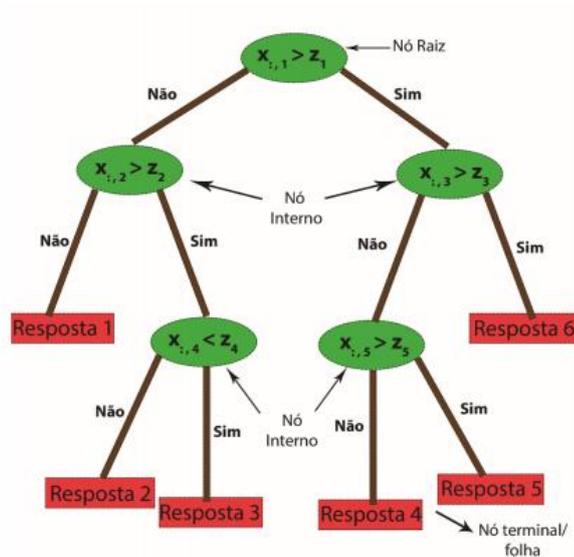
Seus conhecimentos e avanços foram implementados na biblioteca Scikit-Learn, do Python, como uma forma ajudar toda a comunidade a evoluir, dentre essas descobertas incluem: regras de atribuição, critérios de parada e regras de ramificações. A dissertação conclui também que a variância é fruto da correlação entre árvores individuais, reafirmando que a randomização das árvores (ao invés de tentar iniciar o processo com um modelo base de árvore que pode estar enviesado) ajuda a diminuir o erro por generalização em um conjunto de árvores.

Outra de suas conclusões é a importância de uma análise prévia das variáveis a serem utilizadas, variáveis com muita relevância tiveram um papel impactante nos resultados, entretanto, variáveis menos relevantes tiveram um impacto próximo a zero.

A exceção de quando muito restringido pelos hiperparâmetros, dentro de uma floresta aleatória, cada árvore pode, e possivelmente terá, diferentes tamanhos, com diferentes números de nós e folhas. Na Figura 24 é possível observar um pouco melhor a estrutura de uma árvore de decisões. Essa estrutura sempre se inicia com um nó central, que a partir de uma regra, não necessariamente binária, irá gerando ramificações, essas por sua vez irão levar a novos nós, chamados nós internos, onde realizam-se novas ramificações. Ao fim, todas essas ramificações levam aos nós finais, também chamados de folhas.

Outro exemplo de funcionamento das árvores de decisão é o da Figura 25, baseado na aplicação de árvores de decisão à base de dados Iris (FISHER, 1936). A figura (b) indica onde se localizam, com base em um eixo cartesiano, as três diferentes espécies. Na figura (a) está o exemplo de uma árvore de decisão criada justamente para essa classificação.

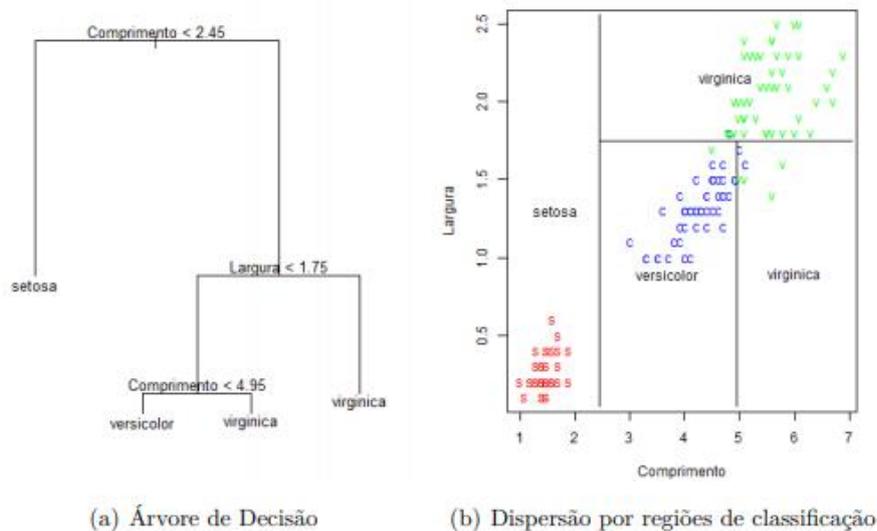
Figura 24: Exemplo da Estrutura de uma árvore de decisão



Fonte: Adaptado de SANTANA (2020)

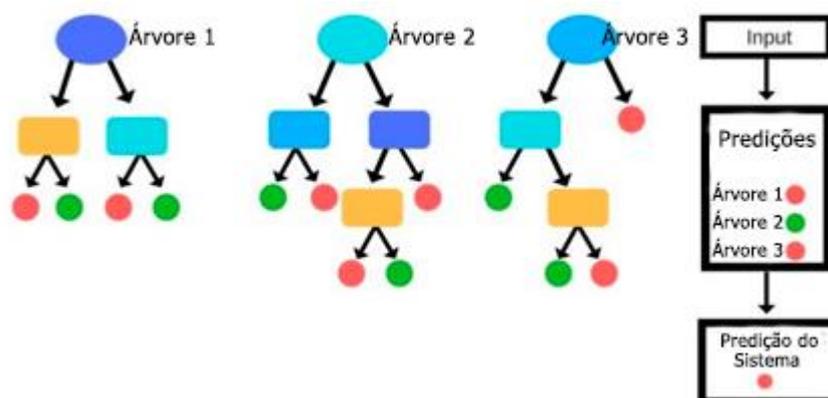
Dentro do classificador, diversas dessas árvores de decisões são criadas, cada uma podendo conter diferentes números de nós internos e de folhas. Analisando a Figura 26, é possível observar um pouco mais dessa estrutura, nela, três árvores com diferentes estruturas de nós são criadas, todas analisando o mesmo dado. Ao fim, o resultado é definido a partir da resposta mais obtida dentre as árvores.

Figura 25: Exemplo de árvore de decisão



Fonte: Adaptado de MORAIS (2017)

Figura 26: Exemplo de uma pequena floresta aleatória



Fonte: Adaptado de DATAASPIRANT (2017)

Dentro da biblioteca *sk-learn* é possível definir diversos hiperparâmetros para a floresta aleatória, dentre os mais importantes estão:

- *n_estimators*: O número de árvores que o algoritmo irá construir. Mais árvores levam a um resultado mais estável e acurado, as custas de exigirem mais poder de processamento.

- *max_features*: Determina o número máximo de *features* que o classificador leva em conta para dividir um nó.

- *min_sample_leaf*: O número mínimo de amostras para se estar em uma folha. Um nó interno só será considerado se deixar mais do que *min_sample_leaf* para cada ramificação.

- *max_depth*: Determina a máxima profundidade da árvore, ou seja, o número máximo de nós internos entre o nó principal e as folhas.

No capítulo 3, são abordadas soluções, tanto de *hardware* quanto de *software*, que mostram como o conhecimento visto no capítulo 2 é essencial para a evolução do estado da arte.

3. ESTADO DA ARTE

O principal intuito deste capítulo é obter um breve panorama dos mais diversos modelos de *hardware* presentes no mercado, bem como um entendimento mais aprofundado dos *softwares* e iniciativas para desenvolvimento de classificadores de sEMG. São dissertados desde soluções mais simples e modestas até as mais modernas e ambiciosas. Ainda nele, uma pequena abordagem sobre os aspectos socioeconômicos das amputações e custos.

Destaca-se como ponto positivo a grande evolução da área nos últimos anos, em publicações relativamente recentes, não só os custos citados são mais elevados, mas também a quantidade de modelos disponíveis é muito inferior.

3.1. Modelos e técnicas do mercado

3.1.1. *Arm Dynamics*

A Arm Dynamics é uma empresa norte-americana, localizada no estado da Califórnia, que busca trazer soluções para todas as diferentes escalas de amputação e para todas as demandas financeiras. É uma das empresas líder neste setor de mercado, além de desenvolverem diversas pesquisas em parceria com universidades, grupos médicos e cientistas.

Os custos para as soluções desta empresa podem variar muito. Isso se deve ao fato da ampla gama de produtos, desde próteses passivas que se assemelham ao membro e que podem custar algumas centenas de dólares, até soluções completas, substituindo inclusive a junção do ombro, nesses casos mais complexos, a prótese pode passar dos 50 mil dólares.

Apesar de possuir um custo mais elevado, a empresa apresenta um vasto catálogo, permitindo ao comprador adequar a melhor prótese ao seu bolso, além disso, oferecem também um acompanhamento no início do processo, para que o usuário possa “treinar” com seu novo membro. Ou como já abordado quando falado sobre as inteligências artificiais, para que o membro possa “treinar” com seu novo usuário.

3.1.2. Tecnologia Mioelétrica

As próteses mioelétricas representam o tipo de tecnologia que inspirou este trabalho. Com ela, a partir dos músculos presentes no membro residual, é possível capturar o sinal gerado pelo estímulo deles, classificar e gerar o movimento na prótese.

Em um resumo da aplicação, eletrodos presentes e em contato com a superfície da pele capturam os sinais elétricos de contração e mandam para o microcontrolador presente. Este dispositivo então interpreta e classifica o sinal, mandando em seguida para pequenos motores responsáveis pelos movimentos da prótese. O mecanismo pode ser de alguns dedos ou mesmo de todo o braço. Obviamente, quanto maior a quantidade de movimentos que a prótese busca recuperar e, quanto maior o grau de amputação, mais complexo e caro se torna todo o processo.

Dedos e mãos mioelétricas são as soluções mais simples dentro deste grupo, uma vez que ainda exista parte ou todo o antebraço disponível para que os eletrodos presos na superfície da pele consigam capturar os pulsos elétricos. Aqui também começam a surgir técnicas de *feedback*, ou seja, maneiras de devolver ao usuário a sensibilidade que ele possuía, seja por pequenas vibrações ou pequenos pulsos elétricos.

As soluções mioelétricas garantem maior independência ao usuário, no caso da prótese da Figura 27, uma pulseira captura os sinais na altura do punho, estes são interpretadas por um controlador embarcado que movimenta os dedos de acordo com o sinal lido. Essa prótese de mão é projetada de maneira a não só repor os dedos perdidos, mas também a trabalhar em harmonia com os ainda existentes.

Figura 27: Exemplo de prótese mioelétrica de mão



Fonte: Adaptado de *Arm Dynamics*.

No caso de amputações totais da mão, o produto engloba toda a extensão remanescente do antebraço, como se fosse uma luva de cano longo, geralmente

utilizando travas na altura do cotovelo. Os sinais lidos ocorrem tipicamente na porção do antebraço mais próxima ao cotovelo. (WIRTA, 1978)

No caso das próteses de mãos e dedos, a quantidade de produtos ofertados é muito superior em comparação aos das próteses de antebraço ou de todo o braço. Isso se deve a alta complexidade de produzir modelos com mais níveis de articulações, além de contarem com um público alvo menor. Outro agravante é o custo, quase exponencial ao número de articulações necessárias. Quanto maior o custo e menor o público, menor ainda será a procura (ZIEGLER-GRAHAM, 2008).

Não é incomum, principalmente entre os amputados com maior poder aquisitivo, que se possua mais de uma prótese, cada uma com objetivos específicos. Uma pessoa hipotética poderia ter uma prótese para o dia a dia, uma a prova d'água para ir à praia, outra, capaz de suportar altas cargas, para a academia, e quem sabe ainda uma quarta para um *hobbie*, como pintura ou escalada.

3.1.3. Hero Arm

Um produto relativamente recente no mercado é o Hero Arm, disponível para venda desde abril de 2018, é o primeiro braço biônico feito com impressão 3D e certificado pelos órgãos médicos competentes. O produto desenvolvido pela britânica *Open Bionics* traz como *slogan* “Welcome to the future, where disabilities are superpowers” ou, “Bem-vindo ao futuro, onde deficiências são superpoderes” em tradução livre.

Ganhou imensa visibilidade dentro do mercado, não só pela altíssima qualidade, mas também pelo preço acessível e grande customização. O produto é desenvolvido para os casos de amputação transradial, onde o produto “abraça” a porção remanescente do membro amputado e segue até o cotovelo. Possui um custo de 5 mil libras esterlinas, algo pouco superior a 35 mil reais segundo o câmbio em junho de 2021. Apesar deste valor aparentar ser elevado em um primeiro momento, ressalta-se que menos de uma década atrás, modelos não tão avançados quanto este chegavam facilmente a 100 mil dólares. A tecnologia que se mostrava quase exclusiva dos mais ricos, hoje está bem mais acessível. Apesar de tudo, ainda não chega nem perto do alcance da maior parte da população, deixando em evidência a importância de mais pesquisas e desenvolvimento nessa área, o que levará a uma constante e gradual

popularização das próteses, para que um dia, todos aqueles que necessitem de uma tenham condições de adquirir.

A produção das próteses é feita a partir de um mapeamento 3D do braço, permitindo assim à *Open Bionics* produzir um braço que seja perfeitamente sob medida. São necessárias cerca de 40 horas para que o braço fique pronto e possa ser usado por qualquer pessoa acima de 8 anos. E empresa possui parceria com a Disney, permitindo ainda mais customizações de design, alguns exemplos desses designs diferentes estão nas Figura 28 e Figura 29.

Figura 28: Modelo da prótese mioelétrica de mão com tema do Homem de Ferro



Fonte: Adaptado de *Hero Arm* (2019).

Figura 29: Modelos da prótese mioelétrica de mão da *Hero Arm*.



Fonte: Adaptado de *Hero Arm* (2019).

O produto, apesar de possuir um custo baixo para a categoria, ainda oferece uma série de benefícios, tais quais possuir um sistema de ventilação para o antebraço e baterias com duração superior a um dia. É possível configurar via *software* algumas posições de mão preferidas, para facilitar o uso no dia a dia ou ainda a possibilidade de usar uma função para congelá-lo, útil para ações corriqueiras como segurar um copo de água ou utilizar uma caneta, por exemplo.

O braço desenvolvido é muito leve, pesando menos de 1 kg e ainda possui uma capacidade de carga para até 8 kg, oferece recursos de *feedback* como luzes, sons e vibrações, permitindo ao usuário uma melhor precisão. No quesito precisão, é possível ainda ajustar a velocidade e a força dos dedos, evitando assim possíveis acidentes. (OPEN BIONICS, 2019)

A *Open Bionics* é uma *startup*, boa parte deste desenvolvimento surgiu com a ajuda de doações e incentivos, mostrando como é possível, com um pouco de esforço, trazer soluções cada vez mais tecnológicas e acessíveis para toda a população.

3.1.4. LUKE Arm

Hoje, o modelo de próteses para membros superiores mais tecnológicos e avançados pertencem a *Mobius Bionics*, empresa de biotecnologia localizada em Manchester, New Hampshire, nos Estados Unidos. O modelo, por sua vez, foi desenvolvido pela *DEKA Research and Development Corp.* Seu nome é uma menção honrosa ao personagem Luke Skywalker, da série *Star Wars*, onde nos filmes, após perder sua mão em uma batalha, precisa utilizar de uma prótese para recuperar seus movimentos e poder novamente lutar.

Disponível no mercado desde 2016, é possível obter o LUKE Arm em três configurações diferentes para diferentes graus de amputação, sendo elas para amputações transradial, transumeral, e desarticulação do ombro, essas três configurações estão demonstradas na Figura 30, em material fornecido pela própria empresa.

A solução para desarticulações de ombro é a única no mercado, até então, que possui também os movimentos do ombro, permitindo que o usuário possa, por exemplo, alcançar objetos acima de sua cabeça.

Figura 30: Os diferentes modelos do LUKE Arm

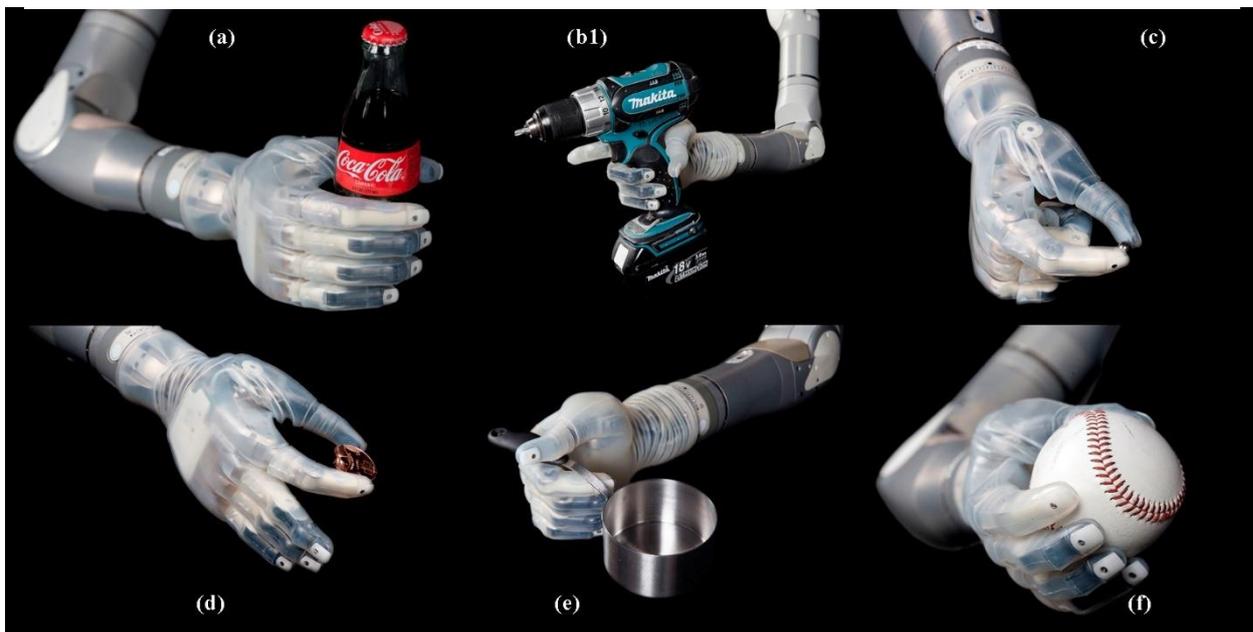


Fonte: Adaptado de *Mobius Bionics* (2019).

As próteses possuem a gama mais completa de movimentos no mercado, com 10 diferentes no modelo para desarticulação de ombro e 6 nas próteses transradiais. São estes movimentos: Adução e abdução do ombro; Flexão e extensão do ombro; Rotação do úmero; Flexão e extensão de cotovelo; Pronação e supinação de punho; Movimentos compostos do rádio e da ulna; Adução e abdução de polegar; Flexão e extensão de polegar; Flexão e extensão do indicador; Flexão e extensão dos outros dedos. (MOBIUS BIONICS, 2019)

Além disso, a prótese conta com 6 diferentes padrões pré-programados, conforme podem ser vistos na Figura 31, junto a um exemplo de como seu manuseio funciona.

Figura 31: Os diferentes grips do Luke arm: (a) Power Grip; (b) Tool Grip; (c) Fine Pinch Closed; (d) Fine Pinch Open; (e) Lateral Pinch; (f) Chuck Grip.



Fonte: Adaptado de *Mobius Bionics*.

O desenvolvimento da prótese é feito sob medida para o paciente, sendo assim, o método de controle pode variar de acordo com a maneira que se mostrar mais eficiente. Existe a opção de EMG para controle da prótese, mas também é possível controlá-la com uma unidade de medidas inercial (IMU) posicionada no pé. Além disso transdutores lineares, de pressão ou algumas outras técnicas podem ser utilizadas. Todo o processo é feito para atender da melhor forma as necessidades dos pacientes.

Para melhorar também o *Feedback* do usuário, os modelos contam com pequenos motores vibratórios que permitem um melhor controle dos movimentos, os sensores que ativam essa vibração estão presentes em vários pontos da prótese e são acionados de acordo com o modo em que se está operando.

Adquirir um destes modelos, entretanto, não é tão barato quanto algumas das soluções anteriores. O modelo, por contar com uma gama muito superior de movimentos, e ser desenvolvido de maneira única para cada usuário, tem um custo que geralmente passa dos 100 mil dólares. Soluções para desarticulações de ombro e que possam envolver muitos detalhes e treinamento do paciente podem passar dos 200 mil dólares.

3.2. Sistemas Classificadores

Os produtos vistos na seção anterior mostram o que há de melhor em soluções completas, onde além da grande necessidade de sinergia entre o sistema classificador e a prótese física, há também muitas etapas de treinamentos e ajustes finos. Isso tudo faz com que, mesmo os produtos no topo de linha ainda sofram com limitações em sua oferta de movimentos.

Essa limitação nas aplicações comerciais ocorre devido a escolhas que visam trazer um maior conforto para o cliente. Torna-se preferível limitar o número de movimentos e até mesmo criar diferentes estruturas de mão pré-programadas, garantindo assim que, mesmo limitado, o usuário consiga em quase todas as operações manifestar o movimento que desejou em sua prótese.

Concomitantemente ao desenvolvimento das versões comerciais, essas empresas, assim como pesquisadores e estudantes do mundo todo buscam elevar ainda mais a qualidade dos sistemas classificadores. Com sistemas classificadores mais robustos, a quantidade de movimentos ofertados pelos modelos comerciais aumenta, assim como a possibilidade de empresas menores e grupos independentes desenvolverem seus modelos de baixo custo.

Devido a questões comerciais e de patente, os detalhes dos sistemas classificadores utilizados nas próteses abordadas na seção 3.1 não são públicos. Portanto, aqui são abordadas literaturas que se destinaram única e exclusivamente ao desenvolvimento dos melhores sistemas classificadores, independentemente de sua aplicabilidade ou sinergia com um modelo comercial.

3.2.1. Projeto NINAPRO e trabalhos relacionados

Todos os bancos de dados contidos dentro do projeto NINAPRO, vistos na seção 2.3, passam por uma validação dos dados obtidos. O conjunto de dados só é considerado completo o suficiente para ser divulgado, caso a equipe consiga reproduzir nele as mesmas taxas de acerto e precisão já vistos no estado da arte.

Dentro dos testes de validação do DB1, feitos em 2012, as margens de erro em um sistema treinado e testado para um mesmo indivíduo e com apenas três movimentos foi, em média, de $7.5 \pm 7.2\%$, quando aumentado para os 52 movimentos do conjunto, a margem de erro aumentou para $20.3 \pm 6.9\%$. Esses resultados foram

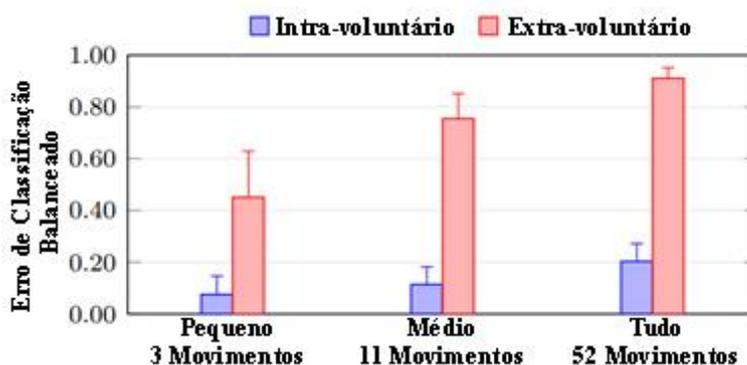
considerados satisfatórios pela equipe, uma vez que condizem com os valores obtidos nos trabalhos mais recentes (ATZORI, 2012).

Nesse conjunto de dados com 10 repetições de cada movimento e com 27 voluntários, foram definidos para o classificador, 5 movimentos para o treinamento e os outros 5 para os testes. A equipe repetiu as classificações 25 vezes, onde a cada rodada, a divisão do que seria destinado ao treino, e do que seria destinado ao teste era feita de forma aleatória. A técnica utilizada para a classificação é chamada de *Least-Squares support vector machine* (LS-SVM) ou Máquina de vetores de suporte de mínimos quadrados, em tradução livre. (ATZORI, 2012)

A escolha de LS-SVM, segundo ATZORI, é devido a sua performance de classificação já ter sido demonstrada como comparável a outras técnicas mais comuns, como visto em *Benchmarking Least Squares Support Vector Machine Classifiers*, pesquisa da Universidade Católica de Leuven, na Bélgica e conduzida por Tony Van Gestel.

A equipe também testou aplicar o sistema classificador treinado com um voluntário nos outros 26 voluntários. Neste caso os resultados pioraram consideravelmente, como pode ser visto na Figura 32. Mesmo para três posturas, o erro médio passou de 40%, por sua vez, com os 52 movimentos o classificador beirou 100% de erro.

Figura 32: Erro médio de classificação para os três diferentes conjuntos de dados. Em azul os testes com o mesmo voluntário no treino e teste. De vermelho os testes treinados com um voluntário e testado com os outros.



Fonte: Adaptado de (ATZORI, 2012)

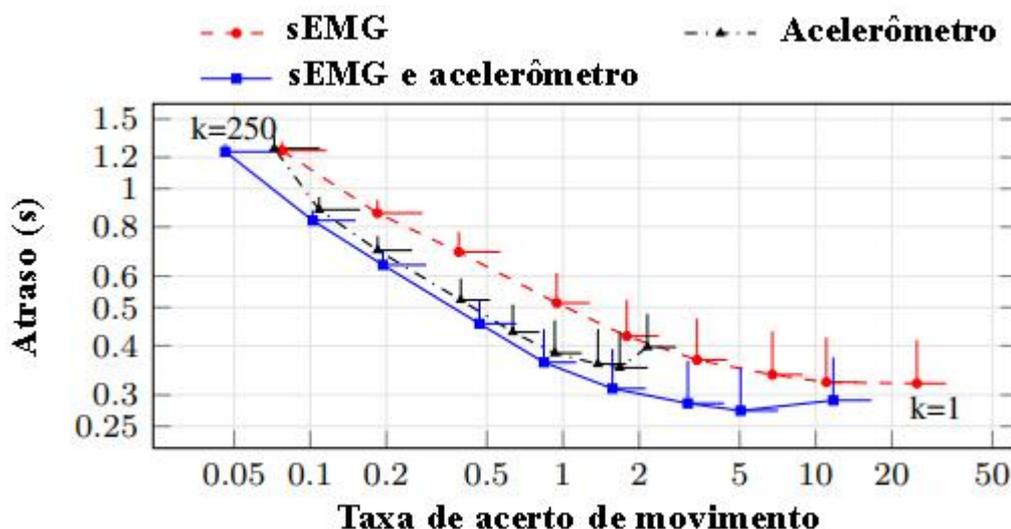
As taxas de acerto foram apenas marginalmente melhores do que o percentual de se acertar aleatoriamente o movimento, indicando que, apesar de haver

uma influência positiva do sistema classificador, ele mostrou-se bem pouco eficiente com relação a testes com indivíduos diferentes dos treinados, reforçando a variabilidade que há nas individualidades biológicas e como um sistema classificador com cunho mais universal precisaria ser consideravelmente mais robusto. (ATZORI, 2012)

Quando a base de dados é obtida de voluntários com amputações transradiais, como é o caso do DB2, o percentual médio de erros torna-se bem mais elevado. No pré-processamento, a equipe normalizou os dados para uma média de tensão em 0V, separou todos os estímulos em janelas de mesma duração e com os movimentos sincronizados. Além disso, extraiu os valores RMS, histogramas, transformada discreta de wavelet e valores médios. (ATZORI, 2014)

Tratando-se do método classificatório, foi utilizado quadrados mínimos regularizados pelo *kernel*, similar ao LS-SVM do teste anterior, porém com alguns benefícios que seriam mais interessantes nessa aplicação, tais quais poder ser aplicado em modelos de regressão e de classificação, além do classificador ter um treinamento que consiste em equações lineares, permitindo que diversas dimensões de resultados sejam treinadas simultaneamente.

O projeto analisou também a relação do tempo de cálculo com a margem de erros. O *delay* obtido, ou seja, a diferença de tempo entre o sinal mioelétrico enviado e a classificação gerada, afeta de maneira considerável o código. Na Figura 33, nota-se como o sistema encontrou pouquíssimos erros quando o delay supera 1 segundo, ao mesmo tempo, considerando faixas de 300 milissegundos, algo mais confortável para o usuário final, as margens de erro tendem a ficar mais elevadas. No caso onde apenas os dados de sEMG são utilizados, a margem de erro em 300 milissegundos chega próxima aos 30%.%.

Figura 33: Relação entre *delay* de resposta e taxa de erros

Fonte: Adaptado de (ATZORI, 2014)

Aprofundando a pesquisa dentro de outras literaturas relevantes sobre esse tópico, observa-se que a taxa média de acertos, no DB1 ou em outros conjuntos de dados semelhantes e com indivíduos não amputados, costuma sempre variar entre 70 e 95%. Essa variabilidade dos resultados é decorrente de algumas escolhas feitas no projeto.

Em síntese, projetos que possuem uma maior base de dados e se propõem a classificar um número menor de movimentos, costumam possuir os resultados mais assertivos. Conforme opta-se por abranger mais movimentos e até mesmo aumentar a velocidade de resposta, maior torna-se a taxa de erros.

No trabalho de Nalband et al (2016), seus resultados variaram entre 75% e 86%. Aceves-Fernandez (2019), tomou o trabalho de Nalband como base e buscou aprimorar os resultados obtidos. Utilizou sinais de EMG obtidos pela sua própria equipe e com 50 voluntários não amputados. Obteve resultados que variavam de 80% de acurácia em movimentos mais complexos de serem classificados até 95% de acurácia em movimentos mais simples.

McIntosh, em 2016, utilizando sensores muito mais próximos ao punho e com uma seleção de apenas 15 movimentos, como vistos na Figura 34, e máquina de vetores de suporte para a classificação dos sinais, conseguiu resultados que alternavam entre 84% e 98%. (MCINTOSH, 2016)

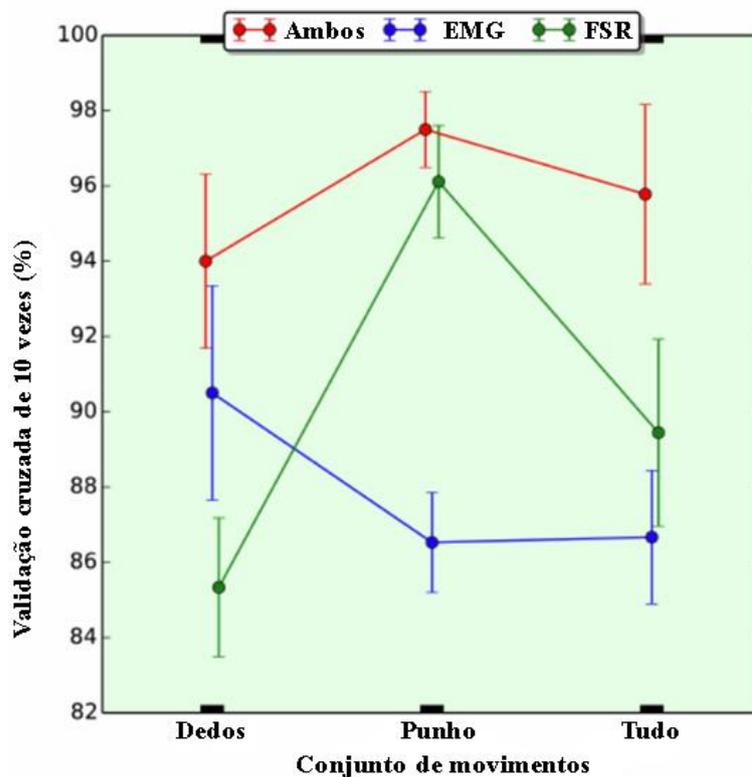
Figura 34: Movimentos que a pesquisa de McIntosh buscou classificar



Fonte: Adaptado de (MCINTOSH, 2016)

No trabalho de McIntosh, foram utilizados sensores de pressão (FSR) em conjunto com o EMG. Observou-se que utilizando os dados de ambos em conjunto é capaz de gerar resultados muito mais satisfatórios, como pode ser visto na Figura 35. Além disso, nota-se uma clara complexidade a mais em classificar o movimento dos dedos em relação aos movimentos de punho.

Figura 35: Validação cruzada das acurácias obtidas por McIntosh.



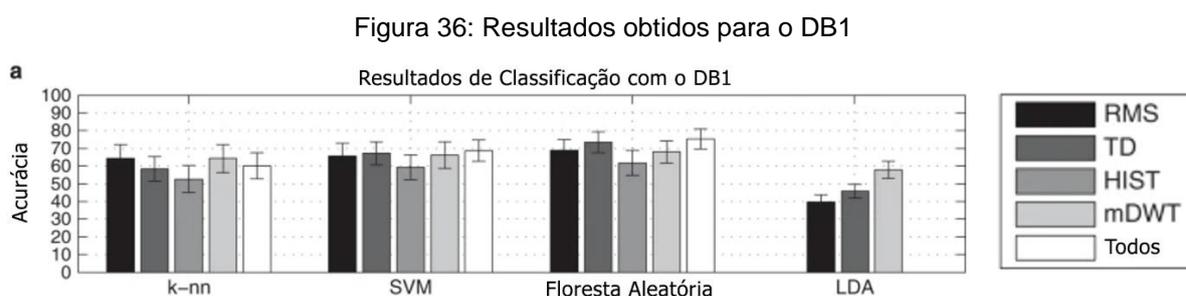
Fonte: Adaptado de (MCINTOSH, 2016)

Essa dificuldade mais específica em se classificar o movimento dos dedos é consequência de sua musculatura ser muito mais sutil e com músculos menos volumosos do que aqueles responsáveis pelos movimentos de punho. Observando o estado da arte em classificadores, as maiores e mais recentes pesquisas obtiveram resultados, onde combinando EMG com outros sinais, para classificação do movimento dos dedos, que variavam entre 80% e 90%. Já para as classificações de movimentos do punho, esses valores tendem a subir para algo entre 85% e 95%. Quando se utiliza apenas o EMG, os resultados mais comuns tendem a ser entre 75% e 85% para os sinais dos dedos e 80% a 90% para os movimentos de punho.

Em um outro estudo de 2014, Atzori *et al* pegaram o DB1 e aplicaram nele alguns diferentes tipos de classificador, além do impacto individual de diferentes *features*. Trabalharam com todos os 52 movimentos do banco de dados, as *features* escolhidas foram valores *Root-Mean-Square (RMS)*, estatística no domínio do tempo (*TD*), Histograma (*HIST*), Transformada *Wavelet* Discreta marginal (*mDWT*) e a combinação normalizada de todos. Já para os classificadores, foram escolhidos o K-

ésimo vizinho mais próximo (*k-nn*), SVM e RF, seus resultados foram comparados com os obtidos por Tenore *et al* (2014) utilizando LDA.

Apesar dos valores individuais das features de Tenore *et al* (2014) estarem abaixo dos de Atzori *et al*. Quando utilizando um conjunto de 11 movimentos, a LDA performou com acurácia média de $89,6\pm 5\%$, superior ao valor encontrado por Atzori *et al* ao tentar reproduzir o estudo, quando obteve $82,77\pm 9,27\%$ de acurácia média

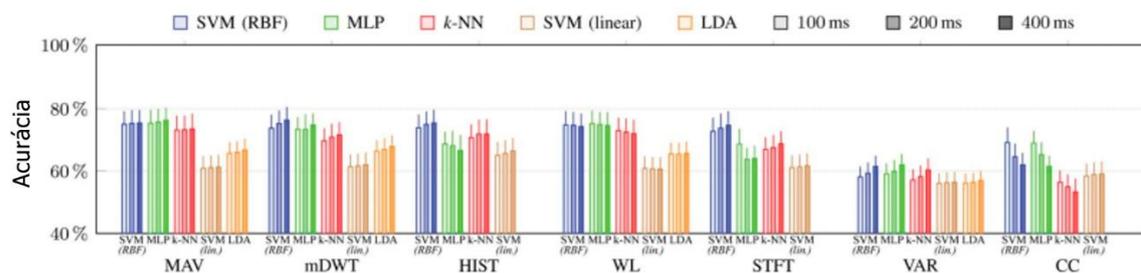


Fonte: Adaptado de (ATZORI, 2014)

Voltando aos resultados do estudo de Atzori *et al*, o grupo encontrou a Floresta Aleatória como tenta a melhor acurácia média, seguido de SVM e por último o *k-nn*. A média obtida para RF ficou em $75,32\%$

Além dos já conhecidos SVM, *k-nn*, e LDA, foi aplicado também um perceptron multi-camadas (MLP). As *features* aplicadas foram MAV, mDWT, HIST, comprimento de onda (WL), variância (VAR), transformada de Fourier (STFT) e coeficientes cepstral (CC). Além disso, testaram-se 3 tamanhos de janelas para os dados, 100 ms, 200 ms e 400 ms.

Na Figura 37 é possível visualizar o resultado de todos os testes realizados, foram avaliados todos os 52 movimentos e todos os 27 indivíduos do DB1. Nela, nota-se como algumas *features* são muito mais impactantes do que outras no resultado, além disso, nota-se como algumas se beneficiam de janelas maiores, enquanto outras obtiveram o exato oposto comportamento. Com esse estudo, o grupo encontrou o SVM não linear, junto do MLP, como sendo os classificadores de melhor acurácia. A melhor acurácia média obtida foi a de $74,01\%$ com o SVM não linear.

Figura 37: Resultado comparando diversas *features*, classificadores e janelas

Fonte: Adaptado de (ATZORI, 2015)

Por fim, na Figura 38 está contido os resultados comparativos de acordo com as diferentes propriedades dos voluntários, a acurácia média utilizada para comparação é a obtida com o SVM não linear, classificador de melhor desempenho nos testes.

Figura 38: Tabela comparando diferentes propriedades e suas acurácias

Propriedade	Grupo	# amost.	Acurácia
	Todos	27	0.7401 ± 0.0394
Gênero	Feminino	7	0.7532 ± 0.0215
	Masculino	20	0.7356 ± 0.0431
Mão	Canhoto	2	0.7380 ± 0.0086
	Destro	25	0.7403 ± 0.0409
Altura	< 172 cm	10	0.7537 ± 0.0207
	172 to 180 cm	8	0.7497 ± 0.0422
	≥ 180 cm	9	0.7167 ± 0.0421
Peso	< 65 kg	9	0.7528 ± 0.0184
	65 to 75 kg	9	0.7512 ± 0.0416
	≥ 75 kg	9	0.7164 ± 0.0418
Idade	< 27 y	7	0.7489 ± 0.0228
	27 to 29 y	10	0.7318 ± 0.0488
	≥ 29 y	10	0.7424 ± 0.0363

Fonte: Adaptado de (ATZORI, 2015)

Como pode ser visto, a maior parte das acurácias obtidas nos diferentes grupos é muito próxima a média geral, apenas em duas variáveis há uma alteração que seja significativa estatisticamente, a altura, para voluntários com mais de 180 cm, e o peso, para voluntários com mais de 75 kg. Segundo essa análise, há uma tendência de piores acurácias em pessoas mais altas e/ou com pesos mais elevado.

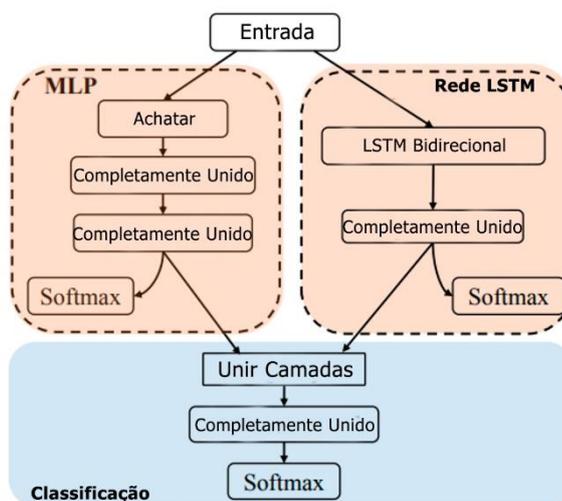
Esse mesmo estudo, apresentado na Figura 37, é na verdade uma releitura, nos mesmos parâmetros, de um trabalho conduzido, em 2012, por Kuzborskij, onde também encontrou o SVM não linear como a ferramenta de classificação mais acurada.

No ano de 2018, He *et al* conduziram um estudo onde combinaram *Long short-term memory* (LSTM), ou memória de curto prazo longa, com um perceptron multicamadas (MLP), essencialmente duas abordagens de redes neurais artificiais. O conceito utilizado foi o de utilizar o LSTM para analisar dependências temporais, ou seja, o impacto dos comportamentos e resultados anteriores no resultado atual, enquanto isso, o MLP foca apenas na classificação quanto aos resultados estáticos.

As premissas seguidas pelo grupo são as mesmas utilizadas por Atzori *et al* em 2016, onde utilizaram redes convolucionais para a classificação do sEMG, além disso, sem o cálculo de nenhuma *feature*, o conceito principal é o de deixar a própria rede convolucional encontrar e calcular suas próprias *features* conforme fizer mais sentido, nesse estudo, Atzori *et al* encontraram uma acurácia média de 66% com o conjunto completo de movimentos, entretanto a fonte de dados utilizada não foi o DB1, dificultando a base para comparações.

O grupo de He *et al*, em 2018, por sua vez, trabalhou com o DB1, criando assim uma boa base para comparação, a Figura 39 traz a apresentação do grupo sobre o funcionamento do seu classificador. Nele, os dois sistemas geram uma resposta em paralelo, que por sua vez são concatenados em uma resposta conjunta.

Figura 39: Exemplo apresentado por He *et al* sobre como funciona seu sistema



Fonte: Adaptado de (HE, 2018)

Como o conceito central é o da própria rede neural ser capaz de identificar e calcular as próprias *features*, o estudo se concentra na melhor configuração para essas redes. Para o LSTM, a melhor configuração foi com 1152 células bidirecionais, já para o MLP, trabalharam com uma camada de entrada de 256 neurônios, a primeira camada oculta com 512, a segunda com 256, e por fim, a camada de saída também com 256 neurônios. A janela de análise foi definida com 400 ms.

Os dados foram divididos meio a meio, sendo então 5 repetições utilizadas para treinamento e outras 5 para testes. Como resultado, o grupo encontrou uma acurácia média de $75,45 \pm 8,97\%$ para os classificadores combinados e $73,19 \pm 8,47\%$ de acurácia média quando utilizaram apenas o MLP. Sendo assim, concluíram que a adição do LSTM buscando um aprendizado temporal é positiva, levando ao aumento na acurácia do classificador com um todo (HE,2018).

3.3. O Brasil E Uma Análise Social

Algo que uma breve pesquisa no *Google* evidencia é a grande escassez de informações, principalmente em português, quando o assunto são próteses de membro superior. Pouco material está disponível e a maioria cobre apenas um conteúdo muito superficial. Aqueles que desejam um mínimo aprofundamento no assunto precisam recorrer à materiais originais em inglês.

Uma segunda dificuldade para o brasileiro é conseguir comprar essas próteses. Apesar de haver, segundo a Lei nº 8.213/91, nos artigos 89 e 90, bem como no Decreto nº 3048/99, o dever do INSS em fornecer pernas mecânicas, braços mecânicos, cadeiras de rodas, muletas e outros tipos de próteses, órteses e demais aparelhos ortopédicos para os segurados e dependentes, há uma certa demora para o recebimento, além de os modelos fornecidos serem os mais simples existentes. Apesar das próteses recebidas não serem os modelos de mais alta tecnologia, são eficientes o suficiente para recuperar o conforto estético e os movimentos básicos.

Um brasileiro que deseje obter essas próteses mais avançadas precisa entrar em contato com empresas no exterior ou com algum revendedor em solo nacional. Como toda prótese mais avançada necessita de acompanhamento individual e uma série de testes, moldes e ajustes, mesmo os modelos mais baratos podem custar

mais de 50 mil reais. Obter modelos como o *LUKE Arm*, considerando todo o deslocamento e câmbio podem facilmente passar do meio milhão de reais e em casos mais complexos alcançar 1 milhão de reais. Além do custo de aquisição, é necessário considerar também os custos de deslocamento e estadia no exterior durante os ajustes e treinamentos.

Em uma matéria do Estadão de 2015 (16), noticiou-se a Linked, *startup* brasileira que produziria próteses biônicas com um custo mais baixo que as demais opções do mercado brasileiro. Nesta matéria, o custo de próteses no mercado nacional está listado como entre 120 mil e 200 mil reais. A prótese da Linked seria feita por 30 mil reais.

Procurando por essa empresa na internet não foi possível encontrar registros atuais dela. Ao que tudo indica o projeto não obteve êxito e infelizmente foi descontinuado.

Ao fim, nota-se como a reintegração de pessoas amputadas torna-se um desafio ainda maior no Brasil. Poucas pessoas realmente conseguem um auxílio e, no fim, precisariam reunir a somatória de 3 a 5 anos de salário mínimo se desejarem adquirir a sua própria prótese com um pouco mais de tecnologia.

Com base nesse cenário, e buscando uma melhora para o país, o próximo capítulo aborda a metodologia empregada no projeto e detalha a criação dos sistemas classificadores.

4. METODOLOGIA

Neste capítulo, são abordadas todas as etapas do processo de desenvolvimento dos sistemas classificadores, buscando tornar claro todas as escolhas e processos feitos. O capítulo apresenta quais os elementos foram levados em questão para a escolha do banco de dados, quais equações e tratamentos são utilizados no sistema classificador e como os resultados foram avaliados

4.1. Escolha do Banco de Dados

4.1.1. Considerações Iniciais

Uma das escolhas mais críticas e impactantes no resultado final é a definição do banco de dados (*DB*) a ser utilizado. Passo essencial para que todas as demais definições de projeto sejam feitas, optar por um banco de dados utilizando dados de voluntários não amputados acarreta em uma expectativa de resultados melhores, porém, não reflete a real situação de uso desejada, ao mesmo tempo, utilizar dados de voluntários amputados pode gerar uma baixa expectativa quanto aos resultados.

Outra questão vista na seção 2.3, onde foram analisados os diferentes bancos de dados dentro do NINAPRO, é a diferença nos *hardwares* de captura. Alguns *DBs* possuem dados com altíssima resolução, o que pode ajudar a alcançar um resultado melhor, porém, ao mesmo tempo sofrer limitações devido ao *hardware* que irá processar os sistemas classificadores, dado esse excesso de dados por segundo que precisará ser calculado. Outros *DBs* mais leves, podem não oferecer a melhor resolução dos dados, mas o tamanho ideal dado a capacidade de processamento.

O último item em questão é a presença, ou não, de outros sinais capturados além do sEMG. Conforme abordado no Estado da arte, os sistemas classificadores que utilizam mais sinais e dados, além do próprio sEMG, possuem uma qualidade de resposta e acurácia superiores àqueles que tomam apenas os sinais mioelétricos como base, porém utilizá-los seria fugir da proposta inicialmente feita.

4.1.2. Justificando a Escolha

Dadas as considerações elencadas na seção anterior, o DB 1, 2 e 9, além do DB10 (ou MeganePro) foram candidatos escolhidos para uma ponderação mais detalhada.

Em uma comparação mais minuciosa, optou-se por descartar o MeganePro, apesar de ser um banco de dados mais completo e avançado, incluindo em suas capturas, sinais como o rastreamento do olhar, dados clínicos e comportamentais dos voluntários, ele acabou trabalhando com uma quantidade menor de voluntários, além de buscar uma classificação que vai muito além dos sinais eletromiográficos ou mesmo sinais que poderiam ser adquiridos por algum *hardware* que estivesse presente na própria prótese.

Em um mesmo caminho, o DB9, apesar de apresentar uma base de voluntários bem ampla, foca em sinais obtidos com a *Cyberglove II* que não se relacionam diretamente ao sEMG, fugindo, assim, do escopo do projeto.

Sendo assim, os DBs 1 e 2 foram os grandes finalistas para a escolha. Esses dois bancos de dados trabalham com voluntários não amputados, o que leva a uma expectativa de acurácia maior. Os maiores contrapontos são o número de repetições e a resolução. Enquanto no DB1 cada movimento possui 10 repetições a uma taxa amostral de 100 Hz, o DB2 trabalha com 6 repetições a 2 kHz. Os arquivos do DB1 possuem um tamanho médio de 20 MB enquanto os do DB2 500 MB.

Optando-se por uma maior quantidade de repetições, arquivos mais leves e de processamento mais rápido, o DB1 foi o escolhido para o trabalho.

4.2. Conhecendo a base de dados

O DB1 é o mais antigo dos bancos de dados dentro do NINAPRO. Conta com os dados de 27 indivíduos não amputados, onde as características deste grupo podem ser vistas na Tabela 2. O *hardware* utilizado na captura foi a *Cyberglove II* e 10 eletrodos do tipo *Otto Bock MyoBock 13E200*, a luva já foi apresentada na Figura 11, presente na página 35. Esse é o mesmo *hardware* utilizado, por exemplo, no DB9, um dos mais recentes dentro do banco de dados.

Tabela 2: Características dos voluntários.

NINAPRO DB1	
Voluntários considerados	27
Homens	20
Mulheres	7
Destros	25
Canhotos	2
Média de idade	28,6 ± 4,23
Média de altura (cm)	173,1 ± 8,26
Média de Peso (kg)	69,4 ± 12,53

Fonte: Adaptado de (ATZORI, MÜLLER, 2012)

A *Cyberglove II* consiste em uma luva com 22 sensores e cada um desses sensores pode ter o seu ganho ajustado individualmente, a finalidade dessa calibração é remover não linearidades no sinal capturado. Contudo, o sinal obtido pela *Cyberglove* não é do tipo sEMG e, portanto, não será utilizado nesse projeto.

O sensor *MyoBock* pode ser visto na Figura 40, opera com um par diferencial, no centro localiza-se o neutro e o sinal capturado é justamente a diferença de potencial entre esse ponto central e os dois eletrodos das extremidades. O aparelho já retifica e amplia o sinal em 14.000 vezes, a taxa de aquisição, como já citado, é de 100 Hz, além disso, o próprio aparelho já possui filtro de linha para 50 ou 60 Hz, a depender do modelo adquirido. Esses eletrodos são tidos na literatura como seguros e confiáveis, e seu uso não requer limpeza especial ou depilação do local (ATZORI, 2012).

O posicionamento dos sensores é feito conforme demonstrado anteriormente, na Figura 8, com 8 deles igualmente espaçados ao redor da porção próxima ao cotovelo e outros 2 logo abaixo, capturando os sinais dos músculos extensores e flexores dos dedos.

Figura 40: O Otto Bock MyoBock 13E200



Fonte: Ottobock, 2020.

Os dados desse DB estão separados individualmente para cada um dos voluntários, informando também o gênero, mão dominante, idade, peso e altura de cada um. Os arquivos baixados são no formato “.zip” e possuem um tamanho médio de 20 MB, internamente, há 3 arquivos “.mat” contendo os dados dos três exercícios realizados por cada participante. Conforme pode ser visto na Figura 41, cada arquivo contém ainda algumas matrizes e outras informações.

Figura 41: Demonstração das matrizes presentes dentro do arquivo “.mat”

emg	101014x10 double
exercise	1
glove	101014x22 double
repetition	101014x1 double
rerepetition	101014x1 double
restimulus	101014x1 double
stimulus	101014x1 double
subject	1

Fonte: Elaborado pelo autor

A matriz *emg*, traz os dados do sEMG dos 10 sensores, dividido em 10 colunas, uma para cada sensor. O arquivo *exercise* informa qual é o conjunto de exercícios desenvolvido, *glove* traz os dados obtidos pela luva, também com uma coluna para cada sensor, *subject* informa qual o número do voluntário. Por fim, os últimos arquivos, *repetition*, *stimulus*, *rerepetition* e *restimulus* trazem os dados repetição, estímulo, re-repetição e reestímulo, respectivamente. Logo mais essas informações são melhor explicadas.

Esse banco de dados passou por duas etapas de testes antes de ser disponibilizado, dependendo de um sucesso em ambas para sua validação. A primeira etapa consistiu em verificar se os dados obtidos correspondem corretamente ao movimento incluído no protocolo de aquisição. A segunda etapa de testes consistiu em verificar se esses dados são similares a aqueles obtidos na vida real.

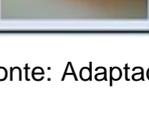
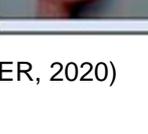
Cada arquivo “.mat” dentro do conjunto de testes do usuário, representa um conjunto de movimentos desenvolvidos por Atzori et al. Os três conjuntos de movimentos, chamados de A, B e C podem ser visualizados nas figuras: Figura 42, Figura 43 e Figura 44.

Figura 42: Conjunto de movimentos A

Conjunto A				
1	Flexão de Indicador		7 Flexão de Mindinho	
2	Extensão de Indicador		8 Extensão de Mindinho	
3	Flexão do Médio		9 Adução de Dedão	
4	Extensão do Médio		10 Abdução de Dedão	
5	Flexão do Anelar		11 Extensão de Dedão	
6	Extensão do Anelar		12 Flexão de Dedão	

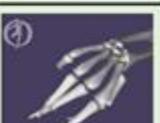
Fonte: Adaptado de (JARQUE-BOU, ATZORI, MÜLLER, 2020)

Figura 43: Conjunto de movimentos B

Conjunto B							
1	Dedão para cima			9	Supinação de punho (eixo: dedo médio)		
2	Extensão de indicador e médio, flexão dos outros			10	Pronação de punho (eixo: dedo médio)		
3	Extensão de indicador, médio e dedão flexão dos outros			11	Supinação de punho (eixo: mindinho)		
4	Dedão na palma			12	Pronação de punho (eixo: mindinho)		
5	Palma aberta			13	Flexão de punho		
6	Punho fechado			14	Extensão de punho		
7	Indicador apontando			15	Extensão de punho com mão fechada		
8	Adução dos dedos estendidos			16	Desvio Ulnar		
				17	Desvio Radial		

Fonte: Adaptado de (JARQUE-BOU, ATZORI, MÜLLER, 2020)

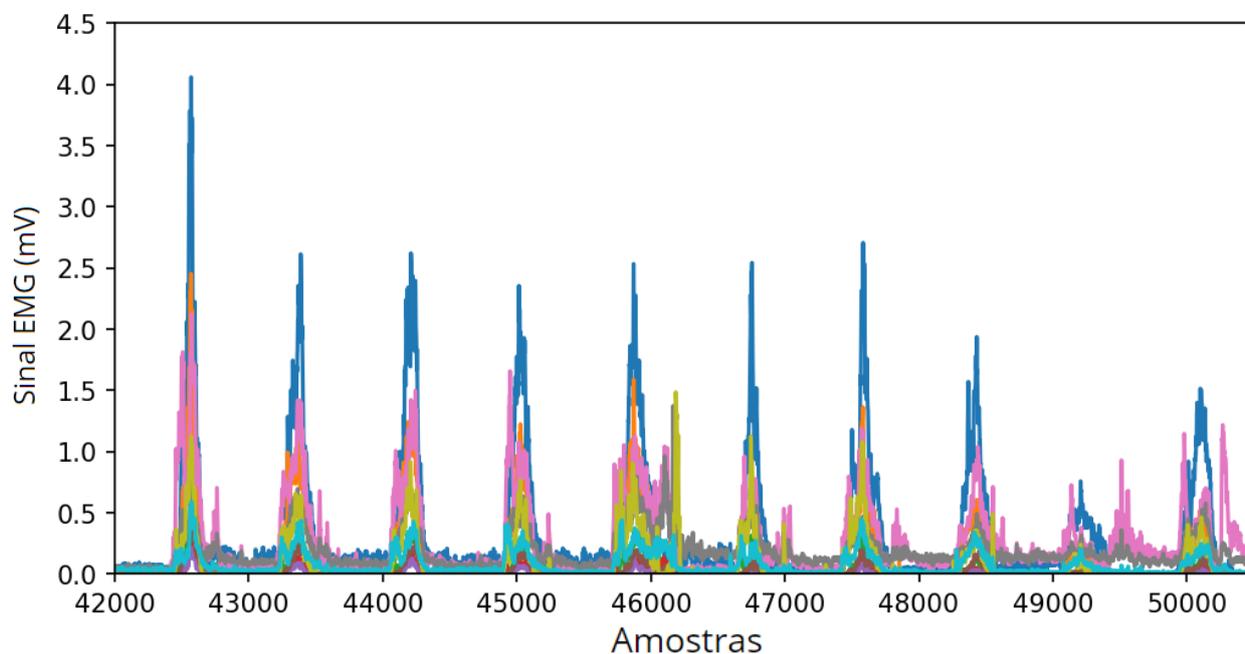
Figura 44: Conjunto de movimentos C

Conjunto C			
1	Pegada diâmetro largo		
2	Pegada diâmetro fino		
3	Pegada gancho fixo		
4	Pegada com extensão de indicador		
5	Pegada média		
6	Pegada em anel		
7	Pegada prismática 4 dedos		
8	Pegada grudenta		
9	Pegada tripé de escrita		
10	Pegada esférica forte		
11	Pegada esférica 3 dedos		
12	Pegada esférica precisão		
13	Pegada tripé		
14	Pinça prismática		
15	Ponta de Pinça		
16	Pegada 4 dedos		
17	Pegada lateral		
18	Pegada extensão lateral		
19	Pegada tipo extensão		
20	Pegada forte disco		
21	Pegada abre garrafa 3 dedos		
22	Pegada grudenta para chave de fenda		
23	Pegada com extensão de indicador para cortar algo		

Fonte: Adaptado de (JARQUE-BOU, ATZORI, MÜLLER, 2020)

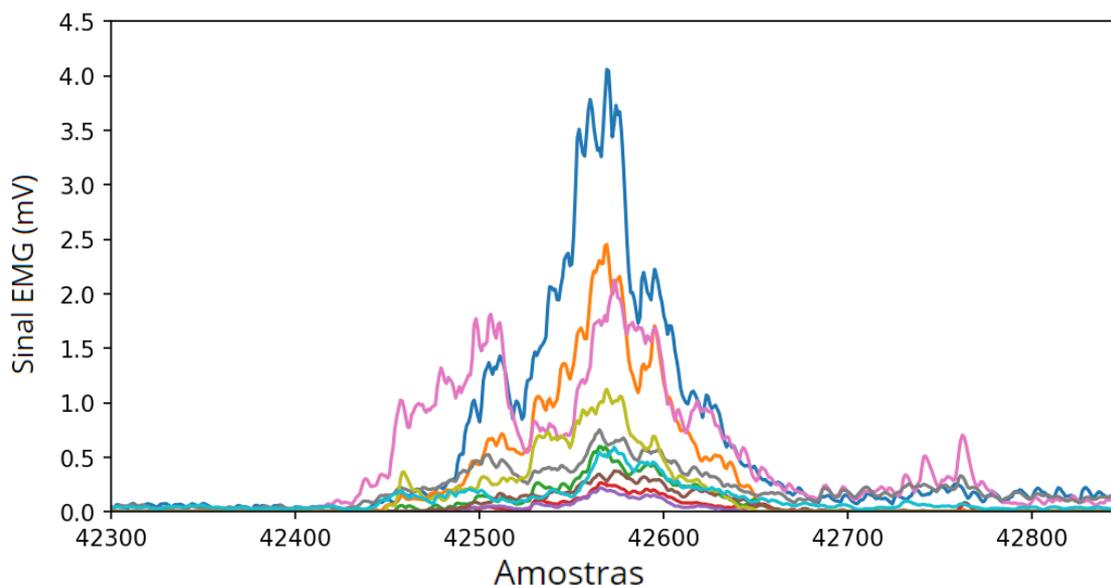
Como cada movimento foi repetido 10 vezes por cada voluntário, há uma boa base amostral para analisar as ondas geradas no sEMG. A Figura 45 representa as 10 repetições do movimento 6 do exercício B, ou seja, o movimento de punho fechado, o sinal demonstrado é o obtido pelos 10 sensores, cada um com uma cor diferente. Na Figura 46, é possível observar de forma detalhada apenas o sEMG de uma repetição desse movimento.

Figura 45: Sinal captado do sEMG para o movimento de punho fechado. Cada cor representa um dos 10 sensores.



Fonte: Elaborado pelo autor

Figura 46: Recorte de apenas 1 dos 10 movimentos



Fonte: Elaborado pelo autor

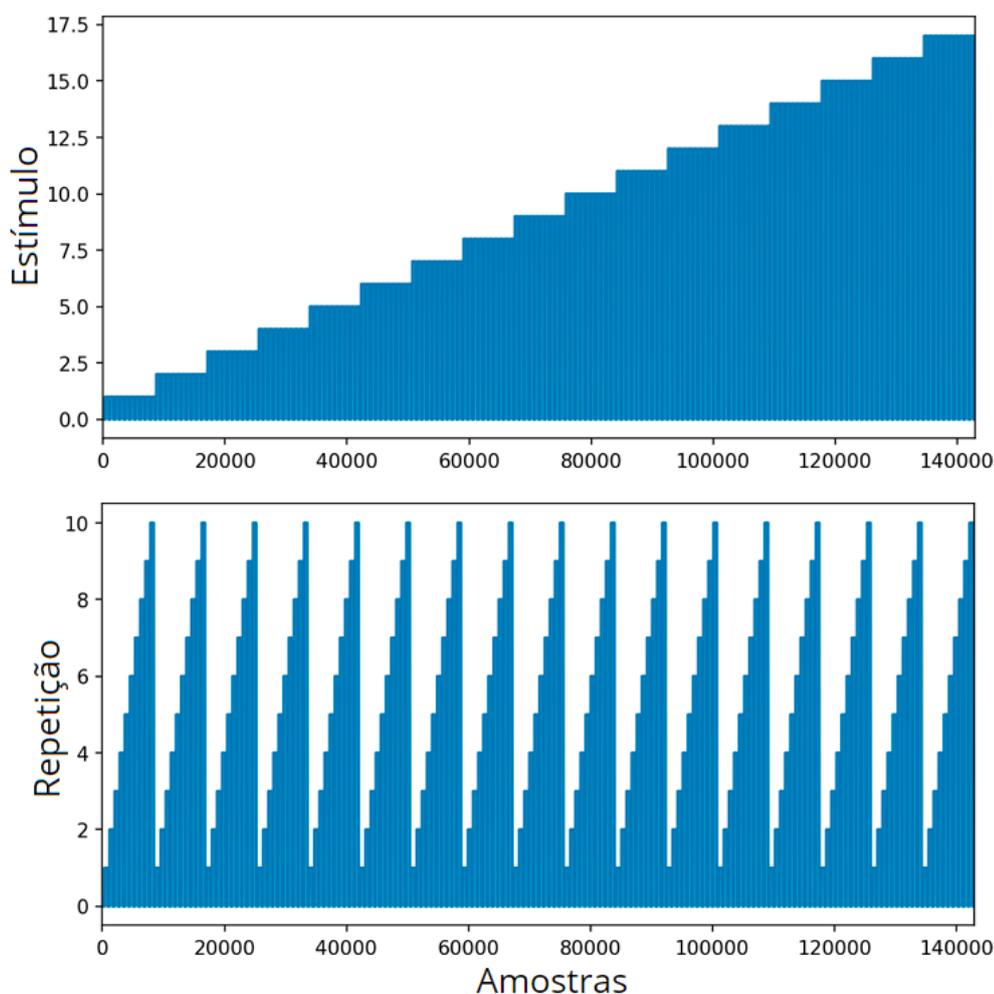
O eixo Y dessas duas figuras representa a intensidade do sinal, já o eixo X demonstra a posição temporal do sinal dentro do conjunto amostral. Como é possível observar na Figura 45, há uma diferença considerável no pico do sinal, principalmente na trilha representada pela cor azul, quando se compara a primeira e a penúltima repetição. Entretanto, ambos os sinais representam o mesmo movimento, existem algumas hipóteses que justifiquem essa diferença, como por exemplo o voluntário ir gradativamente se cansando ao longo das repetições e não as executá-las mais com a mesma força e precisão nas últimas repetições.

Esses detalhes não foram informados por Atzori *et al* (2014) na documentação do banco de dados, inclusive, esse tipo de variação pode muito bem estar inserida dentro do contexto de identidade biológica única de cada indivíduo e reforça como o mesmo movimento pode apresentar uma estrutura eletromiográfica diferente em diferentes momentos. Além disso, os dados capturados refletem condições ideais e sequenciais, mas em situações reais haveriam vários outros fatores que poderiam afetar os sinais: estresse, níveis de sono e concentração no movimento são apenas alguns deles. Cada ser humano é único, portanto, cada classificador deve ser treinado para uma única pessoa. Preferencialmente, com capturas em diferentes momentos do dia e com humores diferentes.

O atual trabalho busca identificar qual o melhor sistema para se classificar os movimentos dada uma situação ideal e condições inalteradas. Porém, quando busca-se aplicar esse mesmo sistema classificador em um indivíduo para uso diário, o trabalho de captura de dados e treinamento deve ser muito mais extenso e bem trabalhado.

Além disso, é importante também explicar o que significa as ondas *repetition*, *stimulus*, *rerepetition* e *restimulus*. As quatro são ondas quadráticas que determinam o intervalo onde ocorre o movimento. A Figura 47 demonstra as ondas de *stimulus* e *repetition*, na primeira, a amplitude informa qual o número do movimento dentro do conjunto de exercícios e há 10 ondas para cada valor de amplitude. Na segunda onda, cada amplitude indica o número da repetição em questão, seguindo em ciclos de 1 a 10 durante todos os movimentos.

Figura 47: As ondas de *stimulus* e *repetition* para o conjunto B de exercícios.

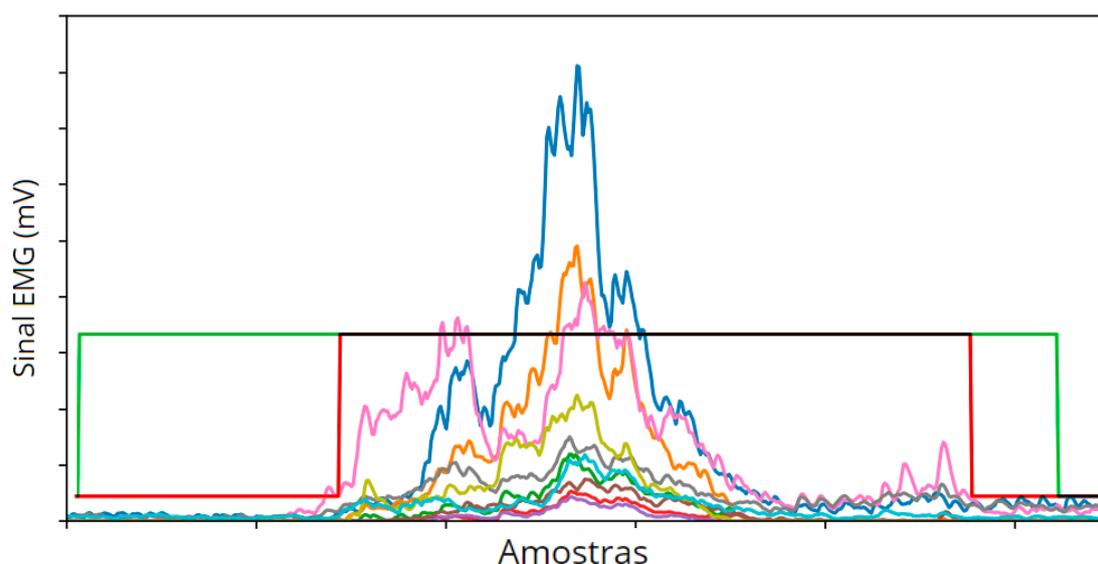


Fonte: Elaborado pelo autor

Dentro do método de captura dos dados, o estímulo foi dado quando o movimento desejado foi representado em um monitor na frente dos usuários, os quais repetiam o mesmo movimento. Algo inevitável é uma janela de estímulo muito maior do que o movimento em si, portanto, a equipe responsável pelos dados fez uma pré filtragem onde isolou apenas os segmentos onde ocorre o movimento, isso gerou duas novas ondas: a de *restímulus* e *rerepetition*. Essas duas ondas possuem exatamente o mesmo comportamento de suas ondas originárias, porém a extensão do sinal é menor, justamente para simbolizar apenas o ponto desejado.

Essa diferença pode ser observada na Figura 48, no exemplo, a mesma onda já apresentada anteriormente na Figura 46 é utilizada. Sobre ela, em verde, está a onda de *stimulus*, demonstrando o período no qual a imagem do movimento era apresentada ao voluntário, como pode-se perceber, há uma boa parte do sinal com apenas algum ruído do repouso. Considerar toda essa janela traria dificuldade para os cálculos matemáticos e lógica que são aplicados, por isso, em vermelho, está a onda de *restímulus* que demarca apenas a porção do sinal que é ligada ao movimento. O sinal fora da onda vermelha são, claramente, os instantes de repouso, porém sem o devido tratamento seriam considerados movimento pelo código.

Figura 48: Movimento de punho fechado, sobreposto pelas ondas de *stimulus* em verde e *restímulus* em vermelho.



Fonte: Elaborado pelo autor

Portanto, para os cálculos e manipulações dos códigos desenvolvidos, apenas as ondas de *restimulus* e *rerepetition* são utilizadas, pois são as duas que trazem apenas os sinais desejados, evitando ruídos.

4.3. Ferramentas utilizadas

A primeira ferramenta utilizada foi o Matlab, *software* que se mostrou mais prático para visualizar e manipular os diferentes dados neste um primeiro momento, deixando-os prontos para posteriormente serem manipulados através do código em Python.

Não há uma exata padronização dos tempos entre repetições e movimentos, portanto, não é possível extrair os dados de forma diretamente matemática. A extração individual de cada onda foi obtida fazendo um “corte” do EMG quando há um valor diferente de zero no sinal de *restimulus*.

Esses arquivos foram cortados e organizados de melhor forma em um ambiente Python, linguagem de programação onde também foram desenvolvidos os sistemas classificadores.

Toda a parte de programação foi desenvolvida no Google Colabs, uma plataforma online que permite o desenvolvimento de códigos Python e com processamento remoto, nos computadores do Google.

As bibliotecas de Python utilizadas foram Pandas, Numpy, Matplotlib, Seaborn, Scipy, TensorFlow e Scikit-learn. Pandas e Numpy são bibliotecas extremamente conhecidas para a manipulação de estruturas de dados, matrizes e vetores, ambas permitiram a importação e manipulação dos sinais do NINAPRO. Matplotlib é uma biblioteca para a criação de gráficos, permitindo a visualização dos resultados, o Seaborn é uma biblioteca que permite maiores alterações visuais nos gráficos gerados, tornando os resultados mais esteticamente agradáveis e legíveis. Scipy é a biblioteca que permitiu a importação dos arquivos .mat.

Por último, os responsáveis pelas inteligências artificiais, o Scikit-learn é uma das bibliotecas mais conhecidas para *Machine Learning*, possuindo em seu repertório todas as funções para a floresta aleatória e a análise linear discriminante. O TensorFlow, biblioteca do próprio Google, possui uma das melhores redes neurais artificiais do mercado e por isso foi utilizada para criar a mesma.

4.4. Modelagem, Extração de Características e Técnicas

Um das primeiras etapas do projeto é definir quais as métricas são calculadas e utilizadas como inputs nos sistemas classificadores. Com base na literatura, optou-se por trabalhar com algumas características do sinal, são elas o *Mean Absolute Value* (MAV), *Root Mean Square* (RMS), *Waveform Length* (WL), *Slope Sign Changes* (SSC), *Standart Deviation* (STD), *Number of Peaks* (NP) e *Mean of Peaks Values* (MPV). Uma breve descrição e o equacionamento para esses parâmetros podem ser vistos na Tabela 3.

Tabela 3: Métricas utilizadas, breve descrição e seu equacionamento.

Acrônimo e Nome	Descrição	Equação
<i>Mean Absolute Value</i> (MAV) / Média dos valores absolutos	É obtido somando-se todos os valores em módulo e dividindo pelo número de pontos	$MAV = \frac{1}{N} \sum_{i=1}^N x_i $
<i>Root Mean Square</i> (RMS) / Valor eficaz	Somam-se os quadrados de todos os pontos sobre o número de pontos e após extrai-se a raiz.	$RMS = \sqrt{\frac{\sum_{i=1}^N x_i ^2}{N}}$
<i>Waveform Length</i> (WL) / Comprimento da forma de onda	Soma-se a diferença absoluta entre todos os pontos da onda. Indica a complexidade do sinal	$WL = \sum_{i=1}^N (x_i - x_{i-1})$
<i>Slope Sign Changes</i> (SSC) / Inversão do sinal	Indica o número de vezes onde houve inversão da inclinação do sinal. O <i>Threshold</i> é definido para evitar que pequenos ruídos possam afetar o resultado.	$SSC = \sum_{i=2}^{N-1} f[(x_i - x_{i-1}) * (x_i - x_{i+1})]$ <p>Onde:</p> $f(x) = \begin{cases} 1 & \text{se } x > \text{threshold} \\ 0 & \text{caso não} \end{cases}$
<i>Standart Deviation</i> (STD) / Desvio padrão	Representa a diferença entre cada amostra de EMG e seu valor médio	$STD = \left[\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 \right]^{\frac{1}{2}}$

<i>Number of Peaks</i> (NP) / Número de picos	Número de picos é o número de valores que são maiores do que o valor RMS do sinal.	$NP = \sum_{i=1}^N f(x)$
		Onde:
		$f(x) = \begin{cases} 1 & \text{se } x > RMS \\ 0 & \text{caso não} \end{cases}$
<i>Mean of Peaks Values</i> (MPV) / Média dos valores de pico	É a média dos valores de pico que foram encontrados na métrica anterior	$MPV = \frac{1}{N} \sum_{i=1}^N x_{NP} $
		Onde X_{NP} representa o valor dos pontos obtidos em NP.

Fonte: Elaborado pelo autor

Os primeiros testes foram feitos apenas com as três primeiras *features* da tabela, e apesar de já serem capazes de trazer um bom resultado, os valores obtidos ainda não estavam condizentes com o objetivo desejado. Sendo assim, pouco a pouco foram-se adicionando outras métricas e verificando o resultado.

As sete métricas apresentadas na Tabela 3 representam o melhor conjunto dentre os testados. O acréscimo de mais algumas métricas poderia melhorar mais um pouco os resultados obtidos, mas conseqüentemente, aumentariam cada vez mais o tempo de processamento, fazendo com que esse sistema se torne lento e desinteressante para posteriormente poder ser utilizado em situações de leitura e classificação em tempo real.

4.4.1. Janelamento

Quando se trata de uma prótese mioelétrica para uso cotidiano, buscar um atraso mínimo entre estímulo e resposta é essencial para o conforto do usuário final. Utilizando como exemplo a onda já vista da Figura 46, ela possui uma duração de aproximadamente 450 pontos, dada a taxa de amostragem de 100 Hz, o estímulo para o movimento tem a duração de 450 ms.

Se neste exemplo, o sistema esperasse todo o movimento acontecer para só então realizar todas as operações matemáticas e, tendo em vista que essas ficam mais demoradas quando há mais pontos, para que só então fosse fazer a classificação, provavelmente o *delay* entre estímulo e movimento estaria próximo a 1 segundo.

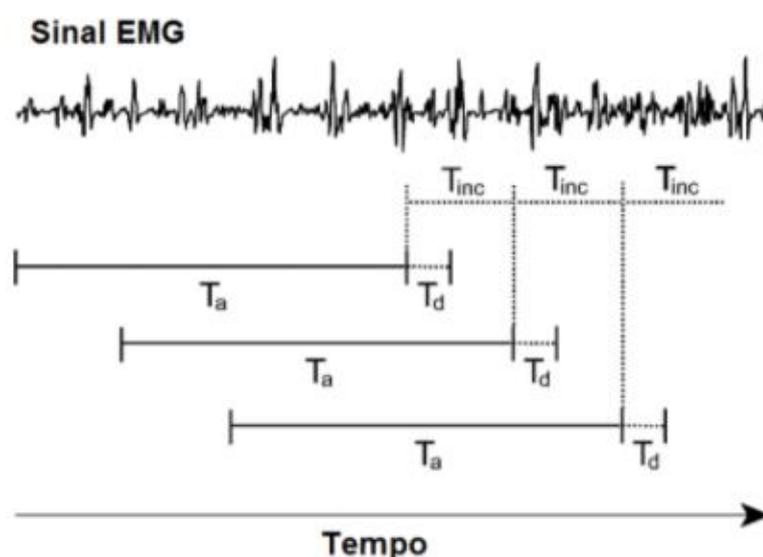
Buscando evitar estes grandes atrasos, fato que tornaria o uso da prótese mais desagradável ao usuário, surge a necessidade de realizar classificações

intermediárias, permitindo assim que a prótese possa iniciar seus movimentos com o mínimo de atraso possível em relação ao estímulo do sEMG.

Esse conceito de classificações intermediárias é chamado de janelamento, onde segmenta-se o sinal do sEMG em pequenas janelas que vão se deslocando ao longo do sinal. Dentro do janelamento há duas variáveis, a “largura da janela” e o “deslocamento”, sendo que quando o deslocamento é menor do que a largura da janela, ocorre uma sobreposição dos sinais.

A exemplo da Figura 49, os incrementos podem ser bem menores do que a própria janela, fazendo com que haja pouca mudança dos dados entre janelas. Essa técnica permite que durante o próprio estímulo, o usuário já comece a perceber o movimento ocorrendo, tornando o uso da prótese muito mais confortável.

Figura 49: Exemplo de janelamento, onde janelas de tamanho T_a se deslocam com incrementos de tamanho T_{inc} , além disso, T_d representa o tempo que o sistema leva pra detectar ou classificar o movimento.



Fonte: adaptado de SMITH (2011)

Segundo Smith (2011), voltado justamente para o processamento de sinais EMG no controle de próteses, foi comparado o efeito de janelas, de 50 ms até 550 ms, onde foi constatado que o erro de classificação diminui conforme se aumenta o tamanho da janela, o ponto adequado sugerido está entre 150 ms e 250 ms. Janelas maiores levariam a uma maior acurácia, porém o atraso de resposta do sistema tornaria inviável o uso em próteses (SMITH, 2011).

Analisando os sinais do banco de dados, observou-se que possuem uma duração média entre 250 ms e 550 ms. Para verificar qual seria a melhor estrutura de janelamento para os dados trabalhados, foram propostos janelamentos de 150 ms, 200 ms e de 250 ms, com deslocamentos de 50 ms e de 100 ms.

Os testes foram feitos com 5 diferentes usuários, com todos os 52 movimentos, o classificador foi a mesma rede RNA usada para a classificação final dos dados. Conforme pode ser visto na Tabela 4, as diferentes organizações de janelamento foram separadas em 6 testes, a acurácia final foi calculada através da média ponderada e do desvio padrão dos testes feitos.

Tabela 4: Relação entre parâmetros do janelamento acurácia média

Parâmetros do janelamento	Acurácia média + Desvio
Janela de 250 ms + deslocamentos de 100 ms	77,57% +/- 2,66%
Janela de 250 ms + deslocamentos de 50 ms	81,16% +/- 1,61%
Janela de 200 ms + deslocamentos de 100 ms	67,70% +/- 2,71%
Janela de 200 ms + deslocamentos de 50 ms	74,89% +/- 3,49%
Janela de 150 ms + deslocamentos de 100 ms	66,68% +/- 1,92%
Janela de 150 ms + deslocamentos de 50 ms	66,98% +/- 9,10%

Fonte: Elaborado pelo autor

Com base no resultado obtido, optou-se por trabalhar com janelas de 250 ms e deslocamentos de 50 ms, esse valor se enquadra dentro do que a bibliografia considera como uma janela confortável ao usuário, corroborando a decisão do projeto (SMITH, 2011).

Dado esse janelamento de 250 ms e frequência da amostra em 100 Hz, pode-se concluir também que todas as variáveis para o cálculo das métricas, vistas anteriormente na Tabela 3, terão o mesmo tamanho, sendo ele de 250 pontos.

A alta acurácia com esse resultado é consequência de duas métricas relevantes para o classificador. A janela mais larga permite que maiores quantidades de dados sejam processadas por cada movimento e um janelamento menor permite que haja uma quantidade amostral maior para treinar e testar os classificadores.

4.5. Escolhendo Diferentes Conjuntos de Movimentos

Não só a literatura sugere, mas também é prática comum entre os fabricantes trabalhar com menos movimentos, o objetivo proposto aqui será ver como o desempenho é afetado ao alterar-se o número de movimentos classificados.

Portando, optou-se por criar 5 grupos de movimentos para serem classificados, o primeiro contendo apenas 5 movimentos, pensados como sendo alguns dos mais utilizados no dia a dia. O segundo com 12 movimentos, o terceiro com 20 movimentos, e o quarto com 35, trazendo um arsenal quase completo para os mais diversos desafios do dia a dia. Por último, o quinto conjunto traz todos os 52 movimentos presentes no banco de dados.

Para facilitar a visualização dos movimentos, numerou-se os movimentos apresentados na Figura 7, já vista anteriormente, de acordo com a sequência dos movimentos nos bancos de dados. O resultado pode ser visto na Figura 50.

Com isso, definiu-se os seguintes grupos com os seguintes movimentos para os testes:

- Grupo 1: 13 – 32 – 40 – 43 – 46
- Grupo 2: 13 – 19 – 27 – 30 – 32 – 33 – 38 – 40 – 43 – 46 – 50 – 51
- Grupo 3: 2 – 12 – 13 – 17 – 19 – 27 – 30 – 31 – 32 – 33 – 35 – 38 – 39 – 40 – 43 – 46 – 48 – 50 – 51 – 52
- Grupo 4: 1 – 2 – 3 – 4 – 10 – 12 – 13 – 14 – 17 – 18 – 19 – 21 – 22 – 25 – 26 – 27 – 30 – 31 – 32 – 33 – 34 – 35 – 37 – 38 – 39 – 40 – 43 – 44 – 45 – 46 – 47 – 48 – 50 – 51 – 52
- Grupo 5: Todos os 52

Figura 50: Os 52 movimentos numerados de acordo com sua sequência nos testes do banco de dados.



Fonte: Adaptado de ATZORI (2012).

4.6. Métricas de Desempenho

A principal métrica de desempenho utilizada neste projeto é a acurácia, ou seja, o número de classificações corretas dado o total de classificações feitas. Uma segunda métrica, um pouco mais subjetiva, é a acurácia individual, ou seja, o número de movimentos acertados dado aquele único movimento, essa informação pode ser observada através da matriz de confusão.

Com a acurácia objetiva-se avaliar o sistema como um todo, vendo quantas vezes o movimento realizado foi corretamente classificado. Na acurácia individual, irá ser visto com um pouco mais de atenção quais os pontos que confundem o classificador e se esse tipo de imprecisão seria crítico ou não no dia a dia.

Criando um exemplo hipotético de análise subjetiva da acurácia individual, com base na Figura 50, um usuário da prótese que tentasse segurar uma bola com o *grip* referente ao movimento 40, mas o sistema interpretou errado e realizou o movimento 41, terá pouco ou nenhum problema, visto que a classificação foi próxima e levou a quase o mesmo resultado. De maneira oposta, supondo que esse usuário vá beber água, segurando um copo com o movimento 32, porém agora o movimento foi classificado como sendo o 17, palma da mão aberta, nesse caso o usuário não conseguirá desempenhar seu movimento e terá problemas.

Esse tipo de análise mais específica é importante para entender melhor os problemas que possam surgir no classificador e ver se ele está cometendo erros grosseiros os apenas confundindo um pouco a posição dos dedos.

Para os cálculos, a acurácia será medida dividindo o número de acertos pelo número total de testes feitos, de uma maneira geral, quantos movimentos o classificador acertou. A acurácia será feita de forma individual para cada movimento, calculando quantas vezes o classificador o acertou dado o número total de vezes que apareceu nos testes. A acurácia individual pode ser uma ferramenta útil para identificar movimentos mais e menos fáceis de serem classificados pelo sistema criado, além disso, a matriz de confusão pode ajudar a identificar movimentos onde os sinais são muito próximos e necessitariam de uma atenção maior em uma nova etapa de captura de dados.

4.7. Estrutura dos Classificadores

Nesta seção será explicado qual a estrutura adotada para os três sistemas classificadores, além de algumas das configurações testadas, mas que não se mostraram tão interessantes quanto as escolhidas nos modelos finais.

Todos os três classificadores possuem a mesma estrutura base, essa estrutura inicia segmentando os dados nos intervalos de janelamento, intervalo este já descrito na seção 4.4.1, na sequência do janelamento, aplica os cálculos das *features*.

Para as *features*, foram utilizados todos os 7 parâmetros já descritos na Tabela 3. Com isso, para cada repetição do movimento há uma matriz de 10 colunas, representando os 10 canais do sinal EMG, e 7 linhas, uma para cada métrica. Com o janelamento, cada repetição do movimento gerará algumas matrizes desse tipo a depender de sua duração.

Portando, para 52 movimentos, as 10 repetições nos levam a 520 segmentos do sinal. Com o janelamento, cada um desses sinais ainda é subdividido em média para outros 5, resultando em pelo menos 2600 matrizes de dados para os sistemas classificadores. Somado a isso, o repouso entre movimentos também foi capturado e separado nas janelas, essa etapa é muito importante, pois o classificador também precisa reconhecer o repouso.

Por padrão, optou-se por utilizar 70% dos dados para treinamento e 30% para testes. Essa proporção só será alterada no sistema com o melhor desempenho geral, onde alguns outros testes são feitos para ver como a variação de proporção treino/teste afeta a acurácia.

Como há uma alteração no padrão do sinal sEMG ao longo das 10 repetições, foram escolhidas para a etapa de teste as repetições 2, 5 e 8, buscando encontrar assim um maior equilíbrio nos resultados.

Com isso, está pronto o código base que será utilizado para todos os três sistemas classificadores. Utilizar exatamente o mesmo processo para os classificadores é essencial, pois só assim é possível comparar as suas eficácias frente um mesmo banco de dados.

Outro ponto importante é que todos os três classificadores irão analisar os mesmos 10 indivíduos, garantindo assim também total isonomia quanto as dificuldades de classificação. Do DB1 do Ninapro, foram escolhidos os seguintes indivíduos: 1,2,3,4,5,7,9,11, 23 e 24.

Na construção das matrizes de confusão, cada classificador irá analisar cada indivíduo duas vezes para cada conjunto de movimentos. Já na construção de dados para a análise da acurácia, não são geradas matrizes de confusão e o código é aplicado dez vezes para cada indivíduo em cada conjunto.

Assim, no resultado final, será possível avaliar as possíveis dificuldades e complicações analisando as matrizes de confusão, somado aos testes de acurácia, onde será possível garantir que a acurácia final encontrada seja muito próxima ao desempenho real de cada classificador.

4.7.1. O Classificador com Redes Neurais Artificiais

Primeiro dos três classificadores a ser explicado, o RNA mostrou-se a rede com maior dificuldade das 3 para ser criada e manipulada. A biblioteca utilizada foi o TensorFlow do Google, extremamente robusta e completa, com várias opções de personalização. Essa biblioteca é vista como uma das melhores soluções para RNA em Python do mercado.

A rede neural criada possui 70 neurônios de entrada, representando todos os 70 pontos calculados nas matrizes. Possui ainda duas camadas ocultas densamente conectadas, a primeira com 240 neurônios e a segunda com 480, ambas utilizam o protocolo de ativação “*relu*”. Na camada de saída, utilizou-se 53 neurônios, 1 para cada um dos movimentos, nessa última camada o protocolo de ativação é do tipo “*softmax*”.

Outras variações dessa estrutura interna foram testadas, como utilizar apenas uma camada interna, onde notou-se uma queda na acurácia média, já acrescentar uma terceira ou mais camadas apenas aumentou o tempo de processamento sem conclusivamente melhorar a eficácia. O número de neurônios em cada camada interna também é fruto de uma série de testes, aumentar a quantidade deles aumentou o tempo de processamento sem melhoras na acurácia, já a diminuição de neurônios afetou a acurácia negativamente.

É interessante ressaltar como o TensorFlow possui a característica de eventualmente apresentar variações significativas nos resultados a cada novo treinamento, devido a alguma porção aleatória do algoritmo, algumas execuções do código apresentam um melhor resultado do que outras, além de eventualmente serem obtidos resultados notavelmente abaixo da média, essa característica é comum a todas as inteligências artificiais desenvolvidas, mas é bem mais ressaltado nas Redes Neurais Artificiais.

Citando por exemplo o voluntário 5, que apresentou 93% de acurácia no conjunto com 5 movimentos quando feito o teste para compor a matriz de confusão. Em novas execuções para validação dos dados, essa acurácia variou entre 80% e 95%.

4.7.2. O Classificador com Análise Discriminante Linear

Para a Análise Linear Discriminante, foi utilizada a biblioteca Scikit-learn, diferente do RNA, aqui foi necessário aplicar uma função de “*reshape*” nos dados, feita

apenas para transformar um vetor de matrizes em uma única matriz. As matrizes de 7x10 transformam-se em 70 colunas, com as linhas representando os movimentos. Na prática isso não altera em nada a base de dados, é apenas uma alteração na apresentação dos dados devido as características da biblioteca.

Dentro dos parâmetros adotados para a LDA está o *solver*, que foi definido como *“lsqr”*, em tradução livre significa solução dos quadrados mínimos, essa técnica é muito próxima das que Atzori *et al* (2015) aplicaram em seus trabalhos já citados. As outras duas opções para este parâmetro, *“eigen”* e *“svd”*, não se mostraram interessantes para o objetivo.

A variável *“n_components”* encontrou os melhores resultados estando em 10 e *“Shrinkage”* como NONE.

A análise discriminante linear é uma técnica que por si só já não possui muitos parâmetros e variabilidades, além disso, foi identificado que a maior parte dos parâmetros definidos como padrão já traziam o melhor resultado e, portanto, assim se manteve.

4.7.3. O Classificador com Floresta Aleatória

A Floresta Aleatória, assim como a Análise Discriminante Linear, foi projetada utilizando a biblioteca Scikit-learn. A escolha dessa biblioteca se deve a um fator adicional, como abordado na seção 2.4.4, a eficácia dos seus modelos foi recentemente aprimorada graças aos estudos de Gilles Louppe, fazendo com que seja, dentro dos modelos gratuitos e abertos ao grande público, a melhor biblioteca para se trabalhar com RF da atualidade.

Assim, como na análise discriminante linear, a floresta aleatória também precisa passar pelo *“reshape”*, portanto exatamente o mesmo processo é aplicado para essa base de dados.

Dentro dos hiperparâmetros, o *“n_estimators”* que representa o número de árvores foi definido em 500. Foram testadas diversas configurações com mais e menos árvores, entretanto esse número foi o que gerou melhores resultados e desempenhos, elevar o número de árvores não afetou a acurácia média, apenas o tempo de resposta do sistema. Seguindo com os parâmetros, *“criterion”* foi definido como *“gini”* e *“max_depth”* em *none*, o primeiro é referente aos critérios de ramificação, já o segundo

traz o número máximo de ramificações por árvore. Principalmente quanto ao segundo, notou-se uma melhor acuraria quando deixando o próprio classificador definir o número de ramificações por árvore.

Os parâmetros relacionados a números mínimos de amostras por folha ou ramificação foram mantidos no padrão da biblioteca, pois foi assim que se obteve os melhores resultados. Por fim, o “*random_state*” foi definido em 70.

A quantidade de parâmetros e ajustes possíveis na RF é gigante, durante as análises buscou-se trabalhar com a maior variedade possível e descobrir qual a melhor combinação para o resultado desejado.

Com base na metodologia apresentada, e dada a sua execução, o próximo capítulo irá apresentar e analisar os resultados obtidos.

5. ANÁLISE DOS RESULTADOS

Dado o escopo e os objetivos iniciais do projeto, buscou-se identificar qual seria a abordagem de Inteligência artificial que apresenta os melhores resultados para o desenvolvimento de um sistema classificador de sinais eletromiográficos. Este capítulo iniciará analisando o desempenho individual de cada um dos três classificadores, na sequência, algumas análises mais aprofundadas são feitas para verificar o impacto de pequenas mudanças no resultado final.

Por fim, é feita uma análise cruzada, buscando entender quais são os pontos fortes e fracos de cada classificador e quais seriam os melhores conjuntos de movimentos para se trabalhar.

5.1. Matrizes de Confusão e Acurácia

Os três classificadores foram desenvolvidos com base nos parâmetros abordados no capítulo 4. Inicialmente são trazidas e analisadas as matrizes de confusão, geradas com duas rodadas de testes para os 10 indivíduos em cada conjunto de movimento, logo após, a acurácia média encontrada após 100 execuções do classificador. Os números na diagonal principal das matrizes indicam o percentual de acurácia do classificador para cada movimento específico.

5.1.1. Resultados das Redes Neurais Artificiais

Iniciando a análise com as Redes Neurais Artificiais, esse foi o primeiro dos classificadores a ser desenvolvido e, assim que foi devidamente refinado, começou a apresentar resultados bem satisfatórios.

A Figura 51 apresenta a matriz de confusão obtida para o conjunto de 5 movimentos. Com esse conjunto, obteve-se uma acurácia média de 91,76%, considerando as duas rodadas para cada voluntário. Os movimentos de 0 a 4 representam os 5 movimentos escolhidos do conjunto, a última repetição por sua vez é o repouso.

Esse conjunto se mostrou bastante equilibrado e no geral não há nenhuma discrepância notável. Alguns focos de erros, como a confusão de 5% dos casos de

repouso com o movimento 3, pinça prismática, são decorrentes principalmente do voluntário 11, que acabou movimentando bastante a mão na etapa de repouso, gerando uma pequena confusão no classificador. Também há alguns casos de confusão entre a pinça e o movimento 4, pegada lateral. Por último, também ocorreram algumas confusões com o movimento de pegada lateral sendo confundido como repouso.

Figura 51: Matriz de Confusão para 5 movimentos com Redes Neurais Artificiais

0	0.96	0.01	0.03	0.00	0.00	0.00
1	0.01	0.92	0.02	0.04	0.01	0.00
2	0.00	0.01	0.97	0.00	0.02	0.00
3	0.00	0.02	0.00	0.91	0.05	0.02
4	0.00	0.00	0.00	0.02	0.93	0.05
5	0.01	0.02	0.01	0.05	0.02	0.89
	0	1	2	3	4	5

Valor Real

Valor Predito

Fonte: Elaborado pelo autor

Observando a Figura 52, é possível notar como houveram poucas mudanças entre o conjunto com 5 movimentos e este com 12. A acurácia média diminuiu pouco mais de 2%, chegando a uma média de 89,11%. A mesma confusão entre repouso e o movimento de pinça prismática, assim como com a pegada lateral, continuam a acontecer, principalmente decorrente dos mesmos usuários que se movimentaram durante o repouso. Como a pinça é um movimento sutil, mesmo alguns poucos movimentos no repouso podem levar a essa confusão.

Também é possível notar uma certa confusão entre os movimentos quatro e cinco, que pela tabela são as pegadas diâmetro largo e pegada gancho fixo, movimentos onde a única diferença é o ângulo do polegar

Figura 52: Matriz de Confusão para 12 movimentos com Redes Neurais Artificiais

0	0.93	0.00	0.01	0.01	0.00	0.01	0.03	0.01	0.00	0.00	0.00	0.00	0.00
1	0.03	0.92	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.05
2	0.01	0.01	0.81	0.03	0.04	0.02	0.03	0.00	0.00	0.00	0.00	0.00	0.03
3	0.00	0.01	0.00	0.89	0.02	0.00	0.06	0.03	0.00	0.00	0.00	0.00	0.00
4	0.00	0.00	0.01	0.01	0.91	0.03	0.01	0.01	0.02	0.00	0.00	0.00	0.00
5	0.01	0.00	0.03	0.00	0.05	0.88	0.00	0.01	0.00	0.00	0.02	0.00	0.01
6	0.01	0.01	0.00	0.00	0.01	0.00	0.85	0.05	0.03	0.01	0.00	0.00	0.03
7	0.00	0.00	0.00	0.01	0.00	0.05	0.00	0.92	0.00	0.01	0.01	0.00	0.00
8	0.00	0.00	0.00	0.01	0.01	0.00	0.03	0.00	0.87	0.05	0.00	0.00	0.03
9	0.00	0.00	0.01	0.00	0.00	0.00	0.03	0.00	0.00	0.89	0.00	0.00	0.07
10	0.00	0.00	0.01	0.01	0.04	0.00	0.00	0.02	0.00	0.02	0.84	0.06	0.00
11	0.00	0.00	0.03	0.00	0.01	0.02	0.00	0.01	0.00	0.00	0.02	0.91	0.00
12	0.00	0.07	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.00	0.00	0.90
	0	1	2	3	4	5	6	7	8	9	10	11	12

Fonte: Elaborado pelo autor

Seguindo com as matrizes, a Figura 53 apresenta o resultado para um total de 20 movimentos, a acurácia média sofreu uma queda e ficou em 85,85%, analisando as acurácias individuais, é possível notar como alguns movimentos específicos passaram a ter mais problemas, chegando a uma acurácia média de 60%.

Além dos dois movimentos de garras, semelhantes ao movimento de segurar um copo d'água, que já apresentavam dificuldades nos primeiros conjuntos, há outros dois movimentos que apareceram neste conjunto e causaram mais confusões no classificador. O primeiro destes movimentos é o chamado extensão de dedão, uma

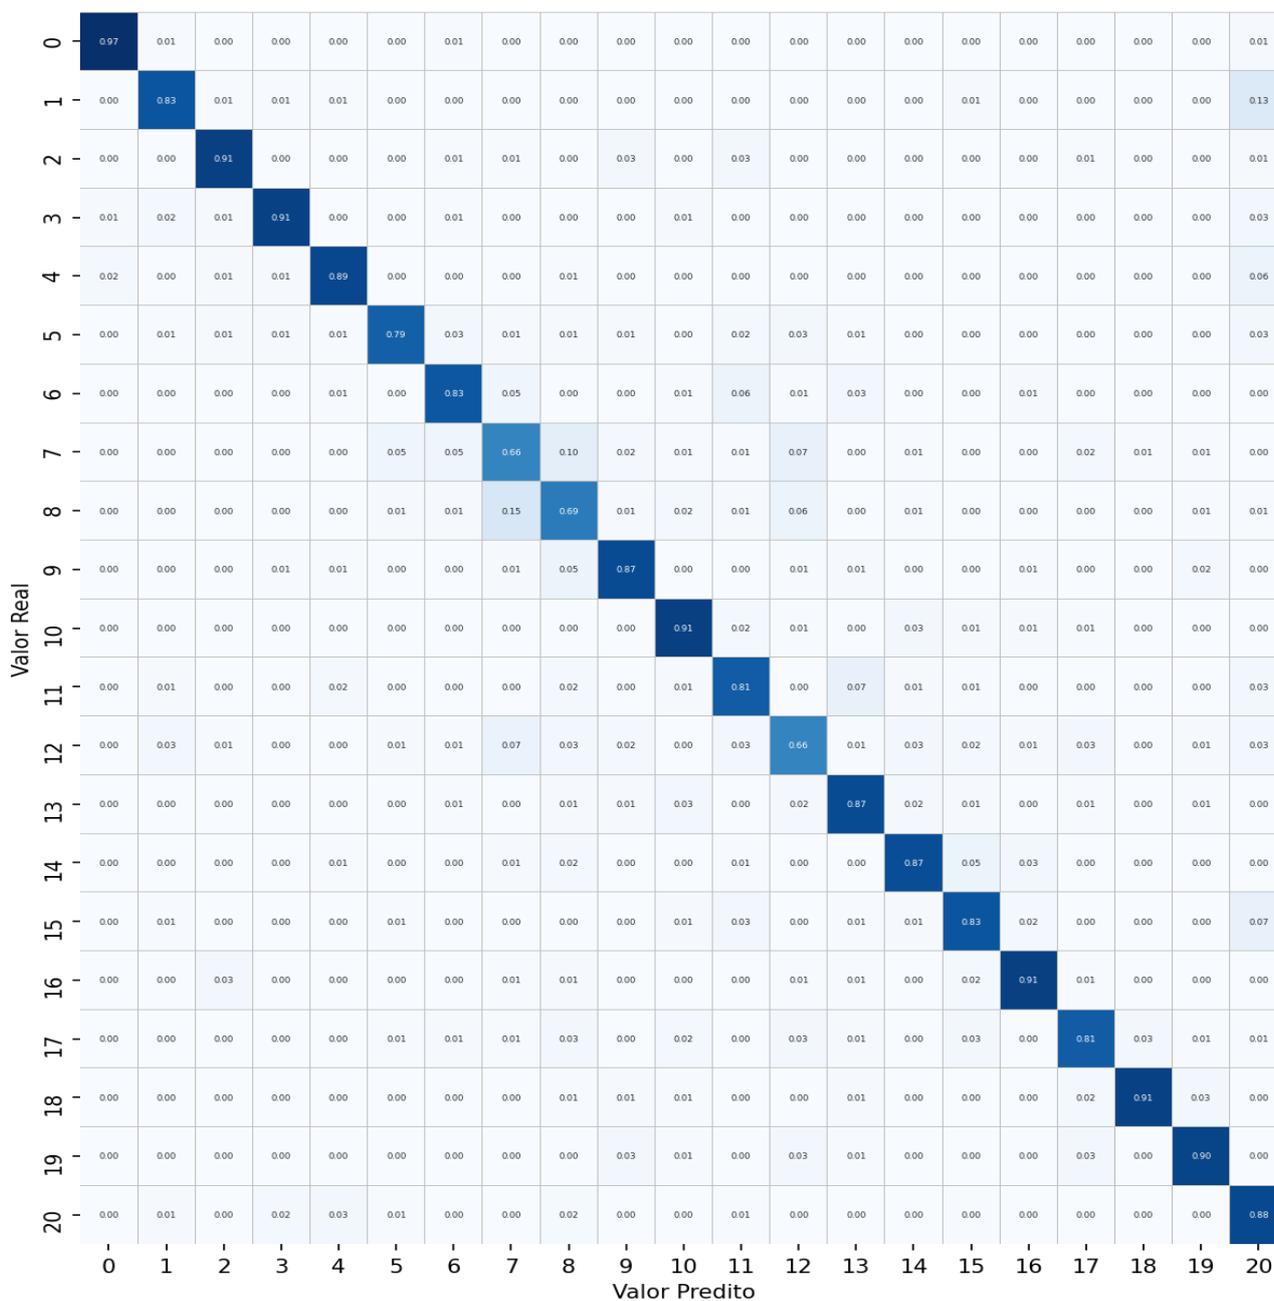
posição de mão muito semelhante à de quando costuma-se estendê-la para cumprimentar alguém, essa posição é muito semelhante a uma posição de mão repousada, o que provavelmente justifica 13% das execuções terem sido classificadas como repouso.

O outro movimento a ter uma maior confusão foi o de pegada esférica, essa posição é relativamente semelhante a outras pegadas e garras, movimentos com os quais o classificador se confundiu.

Neste ponto que começa a tornar-se perceptível o porquê de as próteses a venda terem um conjunto de movimentos definido e limitado, a similaridade entre alguns sinais acaba elevando o índice de confusões na prótese. Da mesma forma, essa alta similaridade poderia indicar que poucos destes casos levariam de fato a algum problema, afinal desempenhariam quase o mesmo movimento. Mesmo assim, uma etapa de pré-seleção nos movimentos disponíveis, escolhendo um conjunto otimizado, poderia facilmente aumentar a acurácia total e o conforto do usuário.

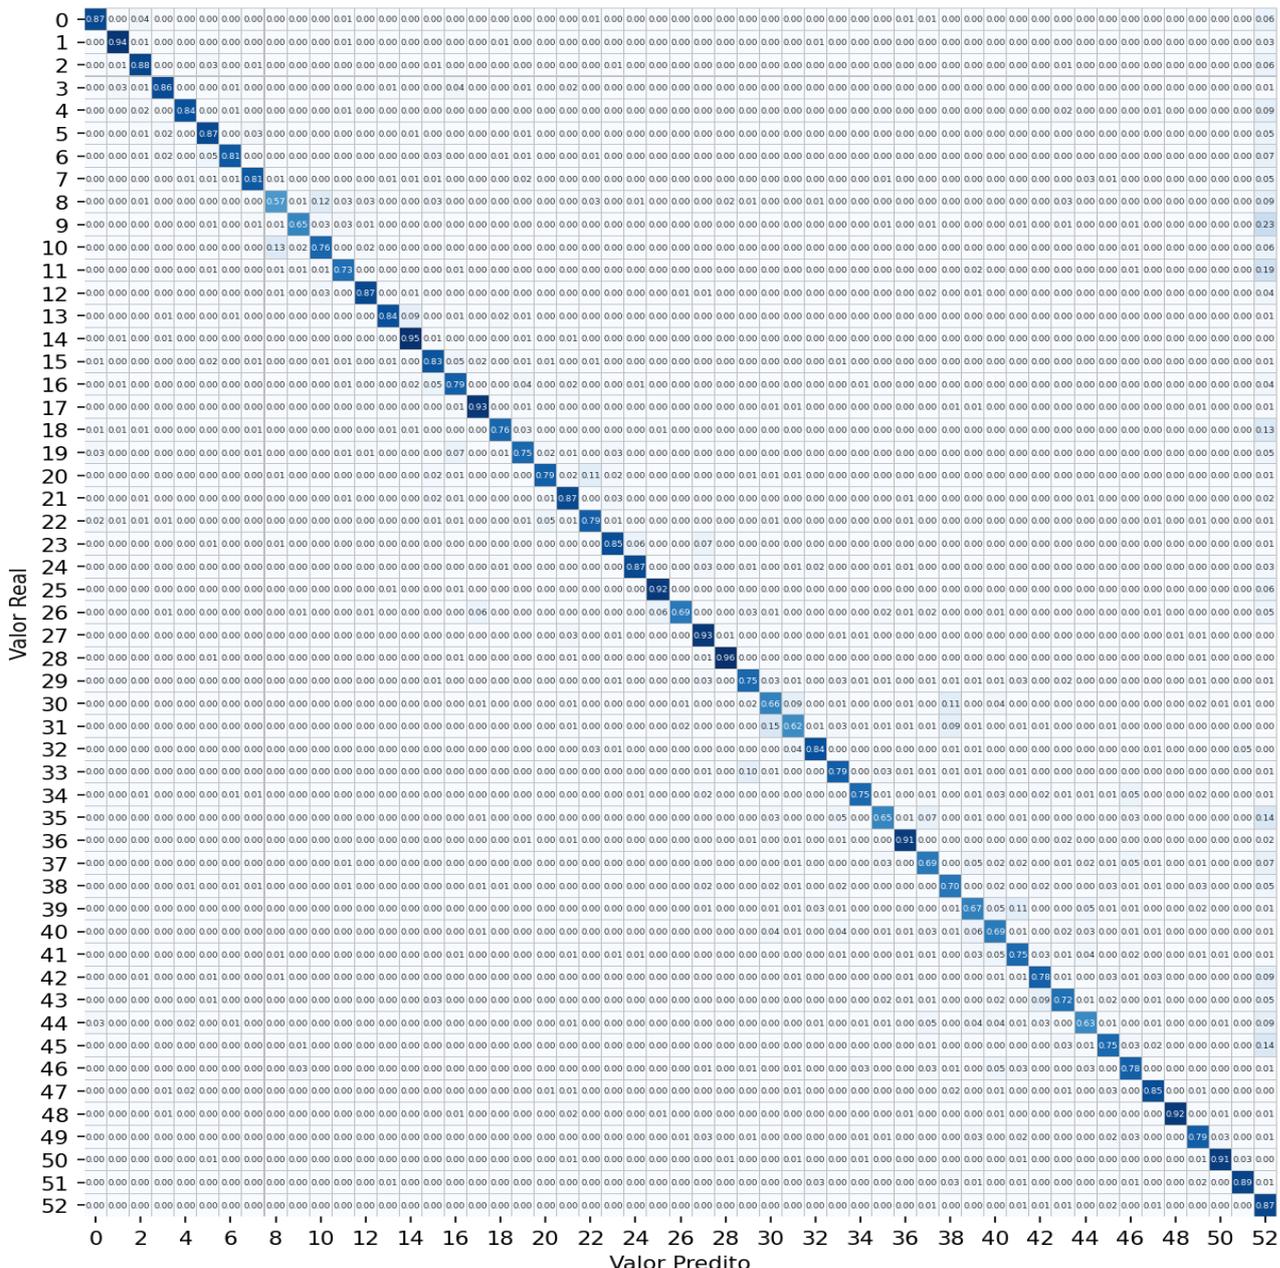
Logo, a Figura 54 representa a matriz de confusão para o conjunto com 35 movimentos. O conjunto obteve uma acurácia média de 82,93% e repete as mesmas confusões já vistas no conjunto de 20 movimentos. Como nos conjuntos maiores há mais movimentos semelhantes, a ocorrência de pequenos focos de confusão é levemente superior.

Figura 53: Matriz de Confusão para 20 movimentos com Redes Neurais Artificiais



Fonte: Elaborado pelo autor

Figura 55: Matriz de Confusão para 52 movimentos com Redes Neurais Artificiais



Fonte: Elaborado pelo autor

Os resultados apresentados foram obtidos a partir das duas execuções do classificador para cada indivíduo, dado o fator da aleatoriedade na construção dos classificadores, optou-se por rodá-los 10 vezes para cada usuário, assim o valor da acurácia obtido é altamente confiável. O resumo desses resultados obtidos está na Tabela 5, como esperado, quanto mais movimentos presentes no conjunto de dados, menor é a acurácia média do sistema, também é possível notar uma certa diminuição no desvio padrão conforme aumentam-se as repetições.

Não há grandes diferenças entre as acurácias obtidas nas matrizes com 20 execuções e os obtidos com 100 execuções, indicando que esse valor de acurácia pode ser considerado como um valor definitivo para os classificadores desenvolvidos e o conjunto trabalhado.

Dentre algumas ressalvas quanto aos resultados, um fato que ocorreu com alguns voluntários, como por exemplo o número 11 já citado, é dessas pessoas terem tido um período de repouso inquieto, agravando as confusões nos movimentos mais sutis.

Citando por exemplo o conjunto de 5 movimentos, o voluntário 2, no seu primeiro teste, teve uma acurácia média de 98,55%, enquanto isso, o voluntário 11 teve 78,26%, mostrando a importância de uma captura de dados bem feita e como características idiossincráticas podem tornar indivíduos mais ou menos propensos a uma boa classificação.

Tabela 5: Acurácia e desvio padrão da média para os 5 conjuntos de movimentos com RNA

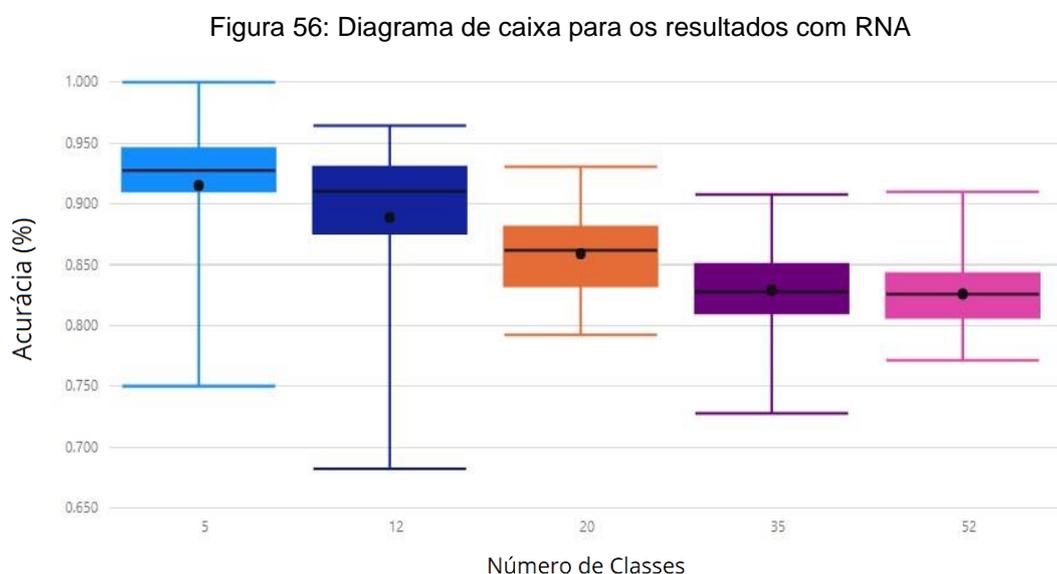
Conjunto:	Acurácia Média (%)	Desvio Padrão (%)
5 movimentos	91,42%	6,05%
12 movimentos	88,88%	7,07%
20 movimentos	85,90%	3,34%
35 movimentos	82,89%	4,09%
52 movimentos	82,59%	2,65%

Fonte: Elaborado pelo autor

Alguns indivíduos, mais do que outros, possuem a características de estarem sempre se movimentando, seja uma perna balançando ou dedos tamborilando, possivelmente o voluntário 11 é um caso de pessoa com essas características e em um caso de aplicabilidade real de uma prótese, a captura de movimentos com ele precisaria ser refeita e/ou conter mais dados amostrais para facilitar o classificador a entender suas características.

A Figura 56 também traz uma visão bem interessante sobre os resultados. Esse diagrama de caixa é muito útil para trazer uma nova visualização sobre os resultados obtidos. Dentro da parte preenchida das caixas estão os valores entre o primeiro e o terceiro quartil, os valores nas linhas finas indicam as zonas foras dos quartis, mas

também quais os limites inferiores e superiores dos resultados. A linha preta representa a mediana, enquanto o ponto preto indica a média.



Fonte: Elaborado pelo autor

Algumas características já são rapidamente observáveis, como a tendência de queda das acurácias conforme aumentam-se os movimentos. O fato de, principalmente no limite superior, ser notável uma queda na acurácia até os 35 movimentos, mas aparentemente não há grandes diferenças para o classificador entre 35 e 52 movimentos, as diferenças de média são bem baixas.

Outro ponto curioso é o fato de o pior limite inferior estar no conjunto de 12 movimentos, enquanto a tendência seria estar em conjuntos maiores. A possível causa para isso está justamente nos indivíduos mais peculiares que foram escolhidos, aparentemente, quando há mais repetições para treinamento, melhor o classificador consegue entender seu comportamento e menos erros comete.

Uma segunda hipótese são essas particularidades dos indivíduos terem ocorrido exata e mais evidentemente nos movimentos escolhidos para os conjuntos menores, causando assim uma queda na acurácia média, já para os conjuntos maiores, esses erros acabam diluídos e não afetam tanto essa acurácia.

5.1.2. Resultados da Análise Discriminante Linear

A segunda análise de resultados será feita a partir dos resultados obtidos com a LDA, seguindo o padrão já estabelecido, esse foi também o segundo classificador a ser desenvolvido.

Na Figura 57, é possível ver a matriz de confusão do LDA para o conjunto de 5 movimentos, a acurácia média ficou em 92,02%, um valor levemente melhor que o obtido com as redes neurais. Destaca-se também o voluntário 9, que nas duas execuções desse conjunto de movimentos obteve 100% de acurácia, enquanto isso, o voluntário 11, que já havia se mostrado problemático com RNA, obteve uma acurácia de 77,54% na primeira rodada e 76,61% na segunda.

O movimento que mais apresentou problemas foi, novamente, neste primeiro conjunto de dados, a pinça prismática, essa confusão aconteceu majoritariamente devido ao voluntário 11 que apresentou pequenos movimentos durante o período que seria de repouso e gerou dados confusos para o classificador.

Logo após, a Figura 58 apresenta a matriz de confusão para o conjunto de 12 movimentos com LDA, a acurácia média ficou em 87,19%. Para esse conjunto, o classificador obteve um resultado aproximadamente 2% abaixo do obtido pelas redes neurais.

Figura 57: Matriz de Confusão para 5 movimentos com Análise Discriminante Linear.

0	0.95	0.00	0.04	0.00	0.01	0.01
1	0.01	0.95	0.01	0.00	0.03	0.00
2	0.01	0.00	0.95	0.03	0.01	0.00
3	0.00	0.01	0.00	0.97	0.01	0.00
4	0.00	0.01	0.01	0.01	0.92	0.05
5	0.01	0.00	0.03	0.07	0.01	0.89
	0	1	2	3	4	5

Valor Real

Valor Predito

Fonte: Elaborado pelo autor

Figura 58: Matriz de Confusão para 12 movimentos com Análise Discriminante Linear.

0	0.95	0.00	0.00	0.00	0.02	0.00	0.03	0.00	0.00	0.00	0.00	0.00	0.00
1	0.00	0.95	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.05
2	0.00	0.01	0.86	0.01	0.01	0.01	0.02	0.00	0.00	0.00	0.03	0.00	0.05
3	0.00	0.00	0.00	0.89	0.05	0.00	0.03	0.02	0.01	0.01	0.00	0.00	0.00
4	0.01	0.00	0.03	0.00	0.94	0.01	0.01	0.00	0.00	0.01	0.00	0.00	0.00
5	0.01	0.01	0.00	0.00	0.01	0.94	0.00	0.03	0.00	0.00	0.00	0.00	0.00
6	0.00	0.00	0.00	0.00	0.00	0.00	0.94	0.03	0.01	0.02	0.00	0.00	0.00
7	0.00	0.00	0.00	0.00	0.00	0.01	0.03	0.89	0.06	0.00	0.01	0.01	0.00
8	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.01	0.94	0.03	0.00	0.00	0.01
9	0.00	0.01	0.01	0.00	0.01	0.01	0.02	0.00	0.01	0.85	0.00	0.00	0.09
10	0.01	0.00	0.00	0.00	0.03	0.01	0.01	0.05	0.01	0.03	0.81	0.05	0.00
11	0.00	0.00	0.00	0.00	0.01	0.00	0.01	0.03	0.00	0.00	0.05	0.91	0.00
12	0.00	0.01	0.01	0.02	0.00	0.00	0.04	0.02	0.03	0.06	0.00	0.00	0.82
	0	1	2	3	4	5	6	7	8	9	10	11	12

Fonte: Elaborado pelo autor

Uma característica que ocorreu com o LDA é a alta discrepância entre resultados, isso pode ser observado, por exemplo, pelo alto desvio padrão da média, que para os dois primeiros conjuntos se aproximou dos 8%, esse mesmo conjunto de movimentos obteve resultados variando de 95% a 72%. Ainda será feita uma rodada de confirmação dos resultados, rodando o classificador 10 vezes para cada usuário em cada conjunto de movimentos e com isso o esperado é chegar a uma melhor conclusão sobre estes valores.

Novamente, neste conjunto de dados, os maiores causadores de problemas foram os mesmo que os mostrados no RNA, a pinça prismática e os movimentos de garra. Ao mesmo tempo, foram obtidos resultados com acurácia de mais de 95% em alguns usuários específicos, indicando que essa possa ser uma boa base de movimentos para uma prótese.

Para o conjunto de 20 movimentos, seu resultado pode ser observado na Figura 59, houve praticamente nenhuma redução na acurácia, agora com 87,03%, o desvio padrão menor também indica que esse resultado se mostrou mais constante ao longo dos voluntários. Existe a possibilidade que uma maior taxa amostral tenha ajudado o classificador a entender melhor os voluntários e com isso solucionar o problema de alguns indivíduos com resultados muito abaixo do esperado.

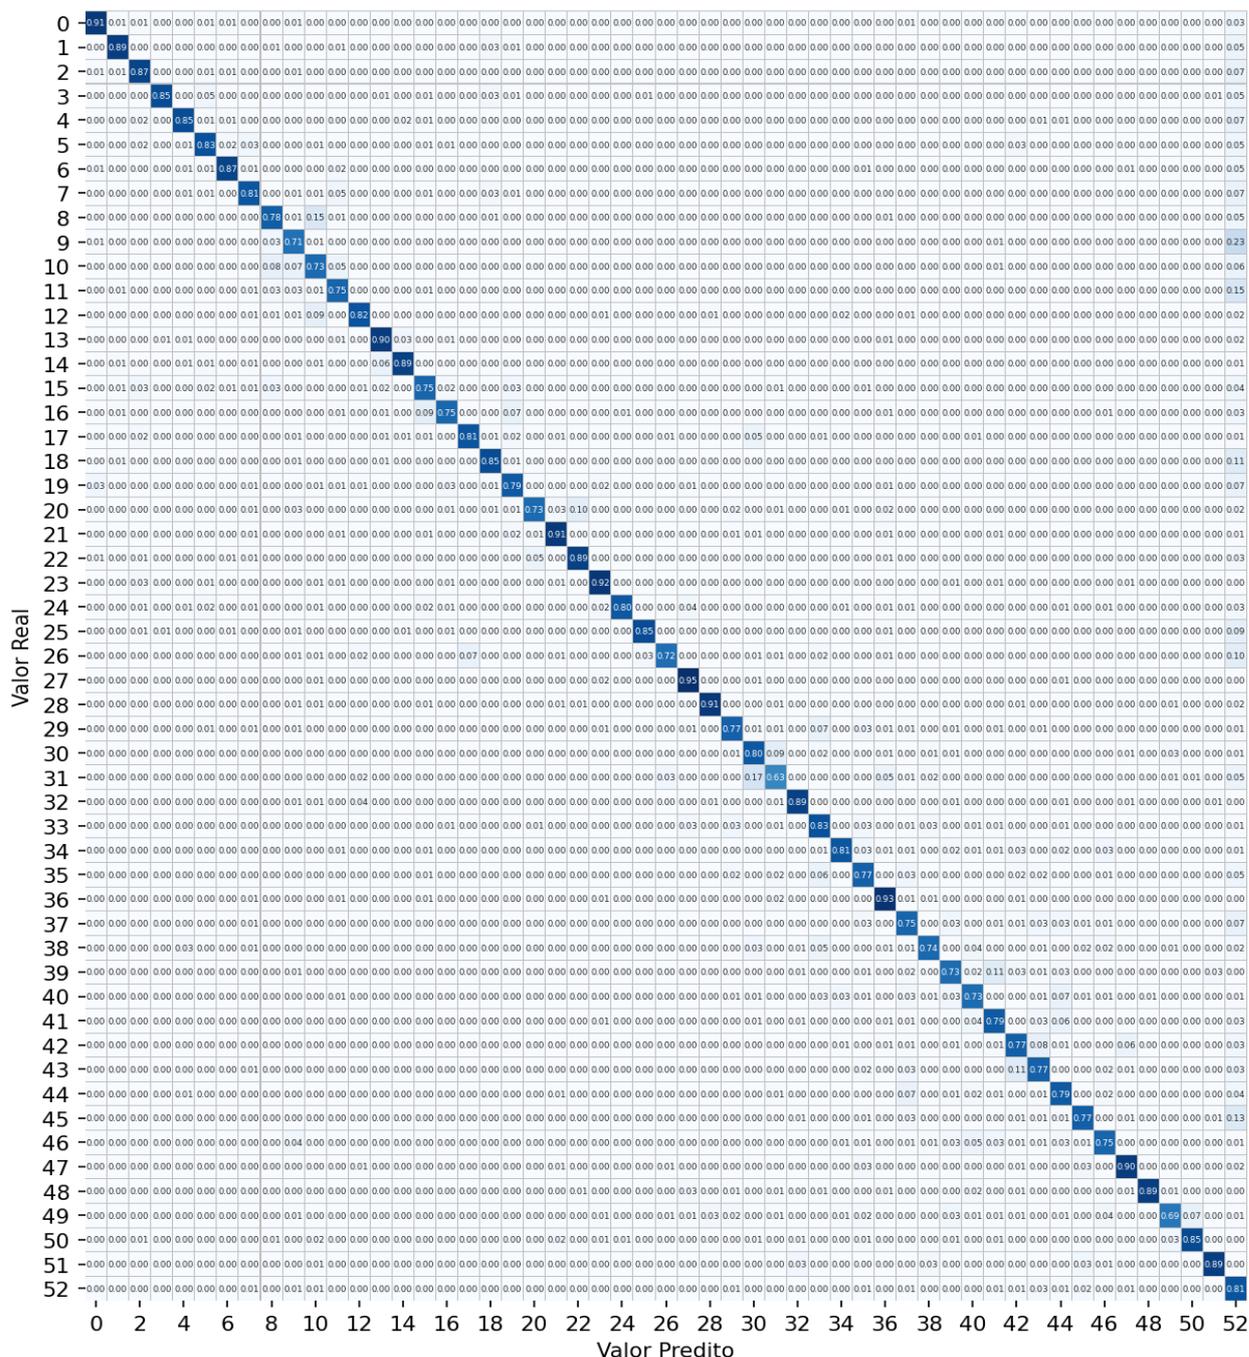
Para os maiores conjuntos de dados, a Figura 60 traz a matriz de confusão para 35 movimentos, a acurácia sofreu uma boa queda, indo para 81,83%. Apesar deste resultado estar um pouco abaixo dos 82% encontrados com RNA, algo que se torna interessante mencionar é a maior linearidade entre as acurácias de cada movimento, quase todos os movimentos orbitaram em 81% de acerto, enquanto com o RNA haviam alguns grupos com altos percentuais e outros com baixíssimos.

Figura 59: Matriz de Confusão para 20 movimentos com Análise Discriminante Linear.

0	0.92	0.01	0.00	0.00	0.01	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.06		
1	0.01	0.85	0.01	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.14		
2	0.00	0.00	0.93	0.01	0.00	0.00	0.00	0.00	0.00	0.02	0.03	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.01		
3	0.01	0.02	0.01	0.90	0.00	0.00	0.00	0.00	0.01	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.00	0.00	0.03		
4	0.01	0.01	0.00	0.00	0.87	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.11		
5	0.00	0.01	0.00	0.01	0.00	0.83	0.00	0.02	0.03	0.00	0.00	0.01	0.00	0.00	0.01	0.00	0.03	0.00	0.06		
6	0.00	0.00	0.00	0.00	0.00	0.00	0.85	0.01	0.05	0.00	0.00	0.04	0.01	0.01	0.01	0.01	0.01	0.00	0.00		
7	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.79	0.12	0.00	0.00	0.00	0.02	0.01	0.00	0.01	0.01	0.03	0.00		
8	0.00	0.00	0.01	0.00	0.00	0.01	0.00	0.19	0.74	0.00	0.00	0.01	0.01	0.00	0.00	0.03	0.00	0.00	0.01		
9	0.01	0.00	0.01	0.00	0.01	0.00	0.00	0.01	0.03	0.91	0.00	0.00	0.00	0.01	0.00	0.01	0.00	0.00	0.01		
10	0.00	0.01	0.01	0.00	0.00	0.00	0.00	0.00	0.01	0.00	0.85	0.03	0.00	0.02	0.03	0.01	0.01	0.01	0.03		
11	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.92	0.00	0.03	0.01	0.01	0.00	0.00	0.02		
12	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.01	0.03	0.01	0.01	0.03	0.87	0.01	0.00	0.03	0.00	0.00	0.00		
13	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.00	0.03	0.00	0.87	0.05	0.01	0.02	0.00	0.01		
14	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.01	0.00	0.01	0.88	0.00	0.09	0.00	0.01		
15	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.01	0.00	0.01	0.00	0.00	0.01	0.84	0.02	0.00	0.09		
16	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.01	0.00	0.00	0.00	0.00	0.00	0.01	0.02	0.95	0.00	0.00		
17	0.00	0.00	0.01	0.00	0.00	0.01	0.02	0.00	0.01	0.00	0.02	0.00	0.00	0.03	0.01	0.04	0.00	0.77	0.07		
18	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.00	0.01	0.00	0.01	0.00	0.01	0.04	0.00	0.00	0.00	0.03	0.89		
19	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.03	0.00	0.00	0.03	0.00	0.00	0.01	0.00	0.01	0.93		
20	0.00	0.03	0.00	0.00	0.03	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.00	0.00	0.00	0.00	0.00	0.00	0.92		
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20

Fonte: Elaborado pelo autor

Figura 61: Matriz de Confusão para 52 movimentos com Análise Discriminante Linear.



Fonte: Elaborado pelo autor

Os problema com alguns voluntários específicos que foram vistos com RNA se repetiu agora com LDA, novamente, esse efeito é mais forte em conjuntos com menos movimentos e vai se tornando quase imperceptível nos maiores, esse fato pode ser visto pelos números na Tabela 6, onde o desvio padrão da média tem uma tendência de queda conforme aumentam-se as repetições.

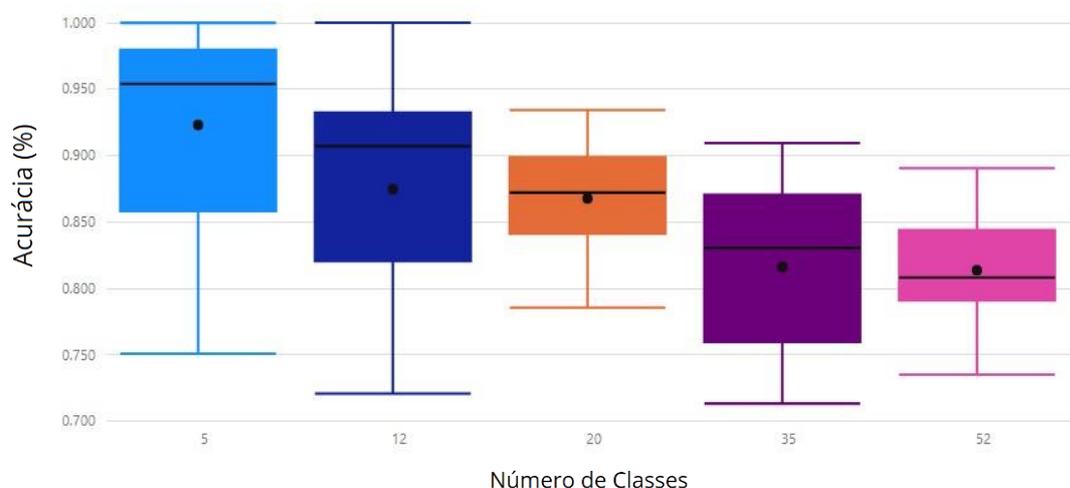
Tabela 6: Acurácia e desvio padrão da média para os 5 conjuntos de movimentos com LDA

Conjunto:	Acurácia Média (%)	Desvio Padrão (%)
5 movimentos	92,31%	7,69%
12 movimentos	87,48%	7,62%
20 movimentos	86,78%	3,70%
35 movimentos	81,63%	5,78%
52 movimentos	81,32%	3,47%

Fonte: Elaborado pelo autor

A Tabela 6 traz os resultados obtidos a partir de 100 execuções do classificador, representando bem qual seria a acurácia final desse classificador dado o conjunto de voluntários trabalhado. O diagrama de caixa presente na Figura 62 reforça alguns pontos já comentados sobre LDA e ajuda a trazer novas ponderações sobre o seu uso.

Figura 62: Diagrama de caixa para os resultados com LDA.



Fonte: Elaborado pelo autor

De uma maneira geral, nota-se como os conjuntos menores de dados tiverem acurácias muito elevadas em alguns voluntários, chegando a 100% com 5 e com 12 movimentos. Em uma primeira análise, parece que há indivíduos com sinais eletromiográficos mais “linearizáveis”, fazendo com que tenham um ótimo desempenho com LDA, ao mesmo tempo, há outros que independentemente de quantas rodadas de teste são feitas, não conseguem atingir uma acurácia tão elevada.

Outro ponto comentado anteriormente e, agora respaldado pelo gráfico, é a maior amplitude de resultados obtidos com LDA. É perceptível como o tamanho das caixas, ou seja, a distância entre o primeiro e o terceiro quartil são maiores, assim como também há uma maior distância entre média e mediana dos resultados.

Muitas das ponderações feitas para as redes neurais podem novamente se aplicar aqui, como o limite inferior de acurácia com 12 movimentos ser bem mais destacado, ou mesmo haver uma tendência de diminuição do desvio padrão.

Em um primeiro momento, parece que o classificador com LDA não foi feito para todos, alguns indivíduos obtiveram resultados excelentes e sempre se mostraram no topo para todos os conjuntos, enquanto isso, outros se mostraram sempre no limite inferior. Para o indivíduo correto, análise discriminante linear é uma ótima ferramenta de classificação: simples, leve e robusta, já para outros não se mostra a melhor alternativa.

5.1.3. Resultados da Floresta Aleatória

Finalizando a sequência de matrizes de confusão, a última a ser desenvolvida foi a Floresta Aleatória. Das três é a biblioteca com mais hiperparâmetros distintos utilizados, diversas rodadas de teste foram necessárias até chegar a melhor combinação, cujos resultados são apresentados nas figuras e tabelas.

A Floresta Aleatória se mostrou uma ferramenta extremamente eficiente de classificação de sinais eletromiográficos. A matriz de confusão da Figura 63, apresentando os resultados do conjunto de 5 movimentos, demonstra um acurácia média de todos os movimentos acima dos 90%, os destaques negativos ficam para os 5% dos repousos sendo confundidos com a pinça prismática e 7% dos movimentos de pegada lateral sendo confundidos com o repouso. A acurácia média dos testes ficou em 92,49%.

Figura 63: Matriz de Confusão para 5 movimentos com Floresta Aleatória.

0	0.99	0.00	0.01	0.00	0.00	0.01
1	0.00	0.97	0.00	0.01	0.01	0.01
2	0.02	0.02	0.92	0.02	0.02	0.00
3	0.00	0.00	0.02	0.93	0.05	0.00
4	0.01	0.00	0.00	0.02	0.91	0.07
5	0.00	0.02	0.00	0.05	0.02	0.91
	0	1	2	3	4	5

Valor Real

Valor Predito

Fonte: Elaborado pelo autor

Analisando individualmente alguns dos voluntários, é possível notar como novamente o usuário 11 ficou com um resultado bem abaixo do esperado, com 76,09%, enquanto isso, os voluntários 5 e 7 obtiveram 98,55% de acurácia, por exemplo.

A essa altura, torna-se evidente a influência do banco de dados no resultado final, se apenas fossem escolhidos os 10 melhores resultados e descartados os outros 10, o sistema teria uma acurácia média de 97,61% nesse primeiro conjunto.

Seguindo com as análises, a Figura 64 traz a matriz de confusão para o conjunto de 12 movimentos, a acurácia média ficou em 91,41%, o melhor resultado para este conjunto dentro dos três classificadores. De maneira geral, os voluntários repetiram praticamente os mesmos resultados da sequência anterior, os focos de confusão são os mesmos que já vistos nos dois classificadores anteriores, porém tiveram um menor efeito na Floresta Aleatória.

Figura 64: Matriz de Confusão para 12 movimentos com Floresta Aleatória.

0	0.95	0.01	0.00	0.00	0.01	0.00	0.01	0.01	0.00	0.00	0.02	0.00	0.01
1	0.01	0.91	0.00	0.00	0.00	0.02	0.00	0.00	0.00	0.01	0.00	0.00	0.06
2	0.00	0.01	0.86	0.00	0.01	0.03	0.01	0.03	0.01	0.00	0.00	0.00	0.05
3	0.00	0.00	0.00	0.89	0.01	0.00	0.03	0.03	0.02	0.01	0.00	0.00	0.02
4	0.00	0.00	0.01	0.04	0.88	0.01	0.01	0.01	0.01	0.00	0.01	0.02	0.01
5	0.00	0.00	0.00	0.00	0.05	0.92	0.01	0.02	0.00	0.00	0.00	0.00	0.00
6	0.00	0.00	0.00	0.00	0.00	0.00	0.93	0.02	0.04	0.01	0.00	0.00	0.00
7	0.00	0.00	0.00	0.00	0.01	0.03	0.02	0.88	0.01	0.01	0.01	0.00	0.03
8	0.00	0.00	0.00	0.00	0.03	0.00	0.03	0.00	0.87	0.05	0.00	0.00	0.03
9	0.01	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.89	0.00	0.00	0.09
10	0.01	0.00	0.01	0.00	0.00	0.01	0.01	0.07	0.00	0.03	0.85	0.01	0.00
11	0.00	0.00	0.00	0.00	0.01	0.01	0.00	0.01	0.00	0.00	0.03	0.95	0.00
12	0.00	0.05	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.94
	0	1	2	3	4	5	6	7	8	9	10	11	12

Fonte: Elaborado pelo autor

A Figura 65 traz a matriz de confusão para o conjunto de 20 movimentos, a acurácia média obtida de 88,13% é novamente o melhor resultado dentre os três classificadores. O destaque negativo é a confusão entre as formas de pegada, além de algumas posições onde a maior parte dos dedos está repousada e que foram confundidos com o próprio repouso. Esses focos de confusão são melhor analisados mais adiante.

Figura 65: Matriz de Confusão para 20 movimentos com Floresta Aleatória.

0	0.91	0.01	0.00	0.00	0.01	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.07
1	0.00	0.83	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.17
2	0.00	0.00	0.93	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.00	0.00	0.01	0.00	0.00	0.01	0.03	0.00	0.00	0.02
3	0.01	0.01	0.03	0.87	0.00	0.01	0.00	0.01	0.00	0.01	0.00	0.00	0.00	0.00	0.00	0.01	0.00	0.02	0.00	0.03
4	0.03	0.00	0.00	0.01	0.87	0.00	0.00	0.00	0.00	0.03	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.07
5	0.00	0.00	0.00	0.00	0.01	0.82	0.00	0.05	0.01	0.03	0.00	0.01	0.00	0.00	0.00	0.01	0.00	0.00	0.02	0.05
6	0.00	0.00	0.00	0.00	0.00	0.00	0.86	0.01	0.01	0.00	0.00	0.03	0.00	0.03	0.02	0.00	0.03	0.00	0.00	0.02
7	0.00	0.00	0.00	0.00	0.00	0.01	0.01	0.83	0.06	0.00	0.01	0.01	0.03	0.00	0.00	0.00	0.03	0.00	0.00	0.00
8	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.17	0.76	0.00	0.00	0.01	0.02	0.00	0.00	0.00	0.00	0.00	0.02	0.01
9	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.05	0.91	0.00	0.01	0.01	0.01	0.00	0.00	0.01	0.00	0.01	0.00
10	0.00	0.01	0.01	0.00	0.00	0.00	0.01	0.00	0.01	0.00	0.85	0.03	0.00	0.01	0.01	0.00	0.01	0.03	0.00	0.02
11	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.00	0.00	0.00	0.94	0.00	0.01	0.01	0.01	0.00	0.00	0.00	0.03
12	0.01	0.00	0.00	0.01	0.00	0.01	0.03	0.05	0.05	0.00	0.00	0.05	0.72	0.02	0.00	0.01	0.01	0.01	0.00	0.03
13	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.04	0.01	0.02	0.00	0.87	0.01	0.01	0.00	0.00	0.00	0.03
14	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.00	0.01	0.03	0.00	0.00	0.82	0.05	0.05	0.00	0.00	0.03
15	0.00	0.01	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.00	0.00	0.00	0.00	0.01	0.85	0.00	0.00	0.00	0.11
16	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.95	0.00	0.00	0.03
17	0.00	0.00	0.00	0.01	0.00	0.01	0.01	0.01	0.00	0.03	0.01	0.00	0.06	0.00	0.02	0.00	0.00	0.81	0.03	0.00
18	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.03	0.01	0.00	0.01	0.01	0.00	0.00	0.00	0.03	0.91	0.01
19	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.06	0.01	0.00	0.02	0.01	0.01	0.00	0.00	0.00	0.00	0.00	0.91
20	0.00	0.01	0.00	0.00	0.06	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.00	0.00	0.00	0.00	0.91

Fonte: Elaborado pelo autor

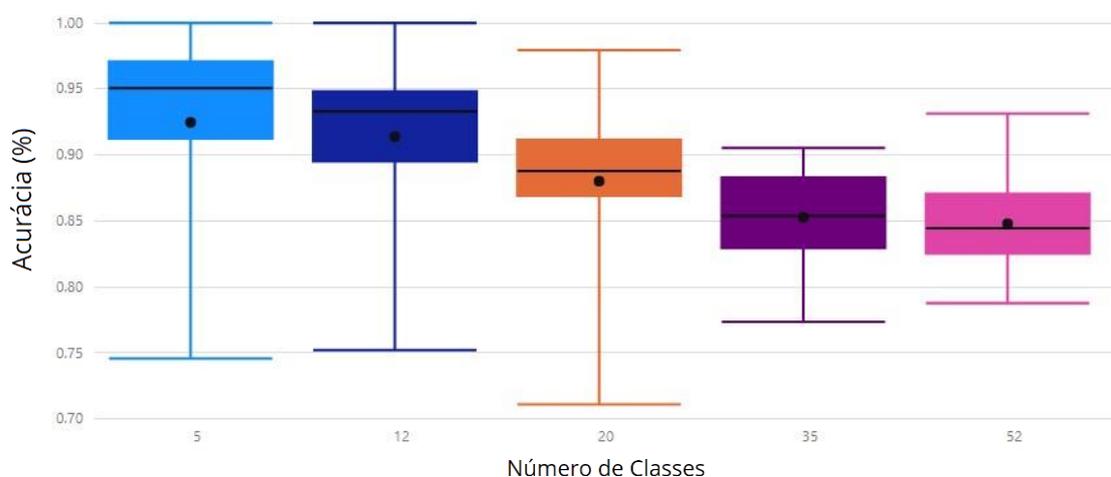
Tabela 7: Acurácia e desvio padrão da média para os 5 conjuntos de movimentos com RF

Conjunto:	Acurácia Média (%)	Desvio Padrão (%)
5 movimentos	92,47%	6,99%
12 movimentos	91,39%	5,69%
20 movimentos	88,01%	6,06%
35 movimentos	85,27%	3,33%
52 movimentos	84,79%	3,06%

Fonte: Elaborado pelo autor

Na Figura 68 está o diagrama de caixa para a Floresta aleatória. Várias análises podem ser feitas a partir dessa imagem. Assim como nas RNA, há uma pequena distância entre o primeiro e o terceiro quartil, indicando que há, para a grande maioria das classificações, uma acurácia média bem próxima a média geral.

Figura 68: Diagrama de caixa para os resultados com RF.



Fonte: Elaborado pelo autor

Ao mesmo tempo que é possível concluir que a grande maioria dos resultados obtidos está bem próximo a média, também é possível notar como esse conjunto obteve alguns resultados bem extremos e fora da média. Dessa vez, os dois conjuntos menores tiveram um limite inferior um pouco mais alto do que o conjunto de 20 movimentos e este, por sua vez, foi onde se obteve o pior desempenho. Uma característica comum aos outros classificadores é que a discrepância entre resultados

diminui bastante nos últimos dois conjuntos, que tem os resultados nos limites inferiores com um melhor desempenho mais próximo a média.

Em uma primeira análise, a floresta aleatória mostrou-se o classificador com melhor desempenho. A acurácia média foi levemente superior quando comparada aos outros classificadores, além disso, considerando apenas os valores entre o primeiro e o terceiro quartil, foi um classificador que apresentou resultados muito consistentes. Por fim, apresenta uma boa linearidade entre as precisões dos movimentos, inferior a LDA, mas superior a RNA.

5.2. Comparando os Classificadores

Essa seção irá fazer uma análise mais minuciosa dos dados obtidos anteriormente, será levado em conta a acurácia obtida com as 10 rodadas de classificação para cada voluntário, utilizando os diagramas de caixas gerados como auxílio para visualizar os dados e facilitar a análise.

Em seguida também será feita uma análise mais detalhada dos diferentes movimentos que causaram confusão nos classificadores, possíveis causas e como poderia ser contornado.

5.2.1. Comparativo das Acurácias

Os três classificadores trouxeram resultados que foram muito alinhados entre si, os melhores e piores voluntários foram sempre os mesmos, assim como há uma grande correlação entre as acurácias individuais dos movimentos ao longo dos testes e classificadores.

Na Tabela 8 está o comparativo dos resultados dos classificadores, como é possível ver, todos os classificadores apresentaram um comportamento muito semelhante, com médias e desvios maiores para os conjuntos pequenos de movimentos e, conforme aumentam-se os movimentos, a acurácia entra em tendência de queda assim como o desvio padrão.

Tabela 8: Comparativo de acurácia entre classificadores

Nº Mov.	RNA		LDA		RF	
	Acurácia (%)	Desvio Padrão (%)	Acurácia (%)	Desvio Padrão (%)	Acurácia (%)	Desvio Padrão (%)
5	91,42%	6,05%	92,33%	7,71%	92,48%	7,01%
12	88,88%	7,07%	87,48%	7,62%	91,16%	5,60%
20	85,90%	3,34%	86,78%	3,70%	87,70%	5,90%
35	82,89%	4,09%	81,63%	5,78%	85,27%	3,33%
52	82,59%	2,65%	81,32%	3,47%	84,79%	3,06%

Fonte: Elaborado pelo autor

A diminuição da acurácia média é o dado mais claro para se entender, quanto maior a base de dados, mais movimentos semelhantes há para se classificar e logo há mais chances do classificador se confundir com os nuances. É mais fácil acertar de 5 a 10 movimentos distintos do que 52, sendo vários desses 52 muito semelhantes.

Já a diminuição do desvio padrão da média possivelmente se deve ao somatório de alguns fatores. Um deles é, possivelmente, devido a uma maior taxa amostral, com mais movimentos contando para a média, faz com que aqueles em específico onde há problemas de classificação tenham um peso relativo menor, evitando que assimetrias pontuais possam afetar o conjunto. Por último, também é importante pontuar que, apesar de todos os tratamentos e cuidados, a base de dados não é perfeita, eventualmente alguns usuários não fizeram a execução perfeita e ideal do movimento, assim como eventualmente não fizeram o repouso da forma ideal.

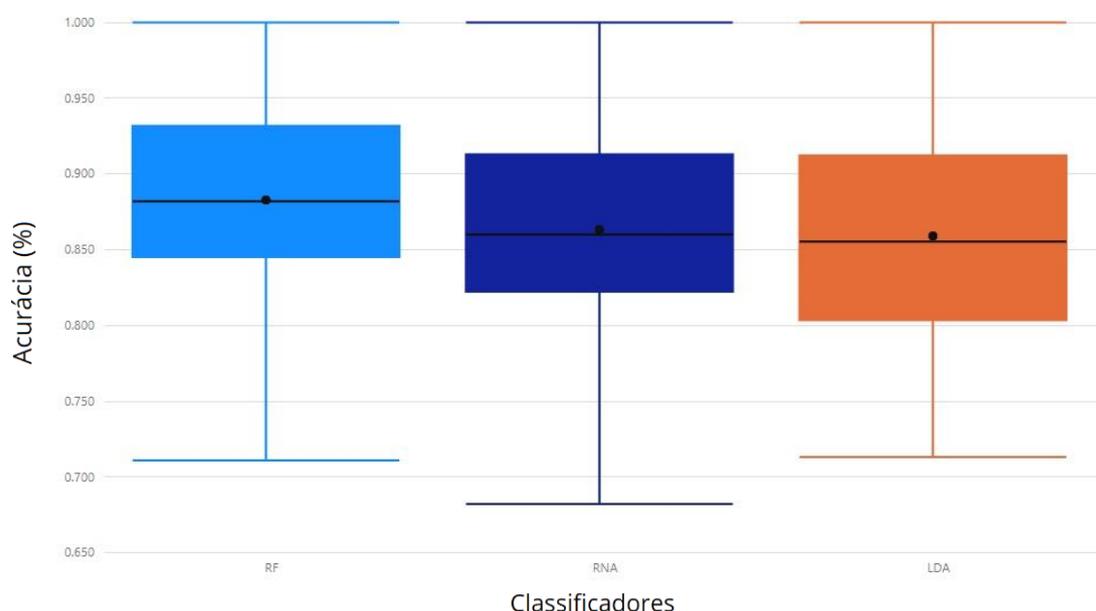
A tendência é no coletivo esses problemas acabarem sendo diluídos, sendo assim, o conjunto com mais movimentos apresenta um comportamento menos variável.

Durante a execução dos testes, foi pensada na possibilidade de trocar usuários, remover aqueles mais problemáticos e colocar novos, mais em linha com os de melhor desempenho, ou até mesmo alterar os movimentos que haviam sido definidos nos conjuntos e colocar novos que apresentaram melhor desempenho. Entretanto, buscar trabalhar com um cenário demasiadamente ideal poderia ser na verdade prejudicial para os objetivos do trabalho, em situações de aplicabilidade real, os movimentos são executados das mais diversas formas, em diferentes horários, com sensores variando levemente de posição e mais uma série de possíveis agravadores.

Sendo assim, o objetivo desse estudo está em encontrar qual o classificador está mais apto a ser utilizado em uma prótese, dada uma situação da vida real e não uma situação ideal. Com os testes feitos, o classificador com maior acurácia média e menores focos de confusão foi a RF, porém, seria possível que em um cenário mais idealizado a conclusão fosse outra, o que poderia levar trabalhos futuros e o andamento do projeto a uma direção errada.

Unindo todos os dados obtidos, construiu-se o diagrama de caixas que pode ser visto na Figura 69. Ele traz todos os resultados obtidos nas 500 rodadas de cada classificador, sem diferenciar os conjuntos de dados.

Figura 69: Diagrama de caixa para os resultados dos três classificadores.



Fonte: Elaborado pelo autor

Citando alguns pontos que podem ser rapidamente vistos, todos os classificadores obtiveram um resultado com 100% de acurácia. LDA e RF tiveram seu pior resultado com pouco mais de 70% de acurácia, já RNA teve seu pior resultado um pouco abaixo dos 70%. LDA e RNA possuem seu primeiro quartil quase no mesmo ponto, porém a variação de resultados com LDA é maior e seu terceiro quartil tem um desempenho um pouco pior, por sua vez, RF apresenta uma acurácia melhor tanto no primeiro quanto no terceiro quartil. Além disso, o gráfico também demonstra uma acurácia média levemente superior na floresta aleatória.

Com todas as análises feitas, é possível concluir que dentre as três técnicas abordadas, a floresta aleatória foi a que apresentou um desempenho mais satisfatório, possui a melhor média, tende a ter um desvio menor e principalmente em conjuntos intermediários de movimentos apresentou um desempenho superior.

5.3. Explorando a RF

Sendo a Floresta Aleatória dentre os três classificadores desenvolvidos, o sistema que apresentou a melhor média de desempenho, parte-se agora para entender como algumas das métricas assumidas como padrão no desenvolver do projeto afetam o resultado final.

5.3.1. Alterando a relação teste/treino

Os resultados obtidos anteriormente pelo sistema foram atingidos utilizando 70% dos dados para treino e 30% para teste. O objetivo agora será variar essa relação de 1 em 1 para os dados de alguns voluntários e ver como isso afeta o desempenho. Os testes foram feitos com o classificador buscando classificar o conjunto de 20 movimentos.

Para esses testes, o código será executado duas vezes, porém apenas para os 5 primeiros voluntários. Estes voluntários tem uma característica de ter apresentado um desempenho médio um pouco superior aos outros 5, e devido a este fator há uma leve melhora nos resultados, espacialmente considerando a relação de 7/3, a mesma utilizada no classificador.

O resultado, como pode ser visto na Tabela 9, demonstra que quanto mais variáveis estão disponibilizadas para treino, melhor é a resposta do sistema frente ao conjunto de teste.

Tabela 9: Relação entre treino/teste com acurácia

Relação treino/teste	Acurácia Média (%)	Desvio Padrão (%)
1/9	57,99%	4,2%
2/8	65,02%	3,1%
3/7	69,47%	2,6%
4/6	72,58%	2,9%
5/5	78,79%	2,6%
6/4	83,08%	2,0%
7/3	92,57%	3,1%
8/2	94,15%	3,7%
9/1	95,14%	3,9%

Fonte: Elaborado pelo autor

Nas análises feitas rodando os 5 conjuntos, uma característica que já havia sido notada é que o aumento do número de repetições para treino também gera uma diminuição nas confusões, levando o resultado final a uma performance mais linear. O aumento no número de repetições acaba diminuindo a acurácia dos classificadores, mas, ao mesmo tempo, menos movimentos mostraram desempenhos consideravelmente abaixo da média.

O resultado obtido nessa análise corrobora bastante com esse ponto, quanto mais movimentos de treino são dados para o classificador, melhor é o seu desempenho. Ao mesmo tempo, trabalhar com uma amostra tão baixa de testes torna difícil ter plena certeza e confiança no resultado obtido.

Em um cenário ideal, seria interessante trabalhar com ainda mais dados de repetições, idealmente ainda capturadas em diferentes momentos do dia, esse conjunto todo de dados permitirá que o classificador desenvolvido fosse ainda mais apto a classificar o usuário em diferentes momentos e situações do dia a dia.

5.3.2. Alterando o número de features

Na Tabela 3 da seção 4.4, foram apresentadas as 7 métricas utilizadas nos cálculos do projeto, sendo elas: *Mean Absolute Value* (MAV); *Root Mean Square* (RMS); *Waveform Length* (WL); *Slope Sign Changes* (SSC); *Standart Deviation* (STD); *Number of Peaks* (NP) e *Mean of Peaks Values* (MPV).

Para os testes de relevância das métricas, será analisado o desempenho do sistema para 20 classes de movimento, em 5 usuários diferentes, rodando o teste duas vezes e com relação de 70% para treino e 30% testes, alterando apenas o número dessas *features* a ser utilizado.

O teste iniciará com todas 7 *features* citadas no início do capítulo, posteriormente, são removidas uma a uma, seguindo em ordem do final para o início da lista. Por fim, o teste finalizará com apenas a métrica de média absoluta dos valores (MAV). O resultado final pode ser observado na Tabela 10.

Tabela 10: Relação entre número de métricas e acurácia média

Métricas Utilizadas	Acurácia Média (%)	Desvio Padrão (%)
7	92,32%	3,3%
6	90,12%	2,4%
5	89,47%	1,9%
4	88,15%	2,3%
3	87,44%	2,2%
2	80,23%	1,5%
1	76,42%	2,1%

Fonte: Elaborado pelo autor

O resultado observado na tabela demonstra o que já foi citado da literatura, onde MAV e RMS possuem quase todas as informações necessárias para classificação do sinal e as demais métricas adicionadas são apenas pequenos complementos que ajudam a elevar um pouco a acurácia.

Foi utilizado o método de *t-test* para analisar a significância estatística entre os resultados. Quando se considera a redução de apenas uma *feature por vez*, não há significância estatística nas reduções de 7 para 6, 6 para 5, 5 para 4 e 4 para 3.

Entretanto, considerando a reduções de duas *features* por vez, todos os resultados se mostraram estatisticamente significativos.

Este resultado sugere que, a partir da terceira *feature*, a adição de novas componentes não gera, em um primeiro momento, uma melhora que seja estatisticamente significativa, porém no conjunto, a somatória dessas pequenas melhoras leva a um incremento estatisticamente significante da acurácia.

Portanto, em uma situação onde se busca desempenho, a adição de uma nova *feature*, em tese, poderia piorar o tempo de resposta sem necessariamente trazer melhoras significativas na acurácia. Além disso, o incremento de *features*, a partir da terceira componente, só seria significativo caso houvesse margem computacional para a adição de duas ou mais novas *features*.

6. CONSIDERAÇÕES FINAIS

Considerando os objetivos iniciais deste trabalho, de criar três classificadores de sinais eletromiográficos utilizando três diferentes técnicas de inteligência artificial, validá-los e compará-los, além de encontrar uma configuração que traga resultados condizentes com o estado da arte, pode-se considerar que os objetivos inicialmente propostos foram atingidos. Além disso, a acurácia encontrada com os classificadores foi acima das expectativas iniciais. Os três classificadores foram plenamente desenvolvidos e validados utilizando o banco de dados DB1 do NINAPRO, o janelamento dos dados foi feito conforme sugerido pela literatura, atingindo valores de acurácia condizentes com o que se encontra em outros trabalhos.

O trabalho com múltiplos tipos de inteligência artificial tornou-se um pequeno desafio, uma vez que foi necessário encontrar uma mesma estrutura de *features* e preparação dos dados que trouxesse um resultado satisfatório aos três.

O DB1 possui uma base de dados robusta e completa, além de contar com uma quantidade interessante de repetições. É importante ressaltar que os indivíduos ali contidos são todos saudáveis e todas as capturas foram feitas sob as mesmas condições, fazendo com que os dados utilizados levassem a uma classificação mais facilitada.

As acurácias encontradas nos três classificadores estão condizentes e, em alguns momentos, até superiores aos valores encontrados em outros trabalhos com classificadores de sinais eletromiográficos para movimentos de mão. Trabalhos estes que também utilizaram o mesmo banco de dados ou outros semelhantes, mas, também, com voluntários não amputados.

O que se destaca são os resultados obtidos, principalmente, pela Floresta Aleatória, possuindo uma acurácia que a coloca no topo dos melhores valores obtidos no estado da arte e, possivelmente, tornando-a uma forte candidata para o desenvolvimento de um sistema mais robusto no futuro. Além disso, demonstrou um ótimo tempo de processamento, permitindo que mais *features* possam ser associadas a ela, além de ter se mostrado ainda mais acurada quando recebeu mais dados para treinamento.

É esperado, ao aumentar o número de movimentos para classificação, que haja uma diminuição da acurácia. Entretanto, a queda na acurácia observada para os três classificadores não reflete o real aumento nessa dificuldade, ressaltando a robustez

dos sistemas desenvolvidos. Esse tipo de resultado traz a esperança de que é possível desenvolver próteses com ainda mais ofertas de movimentos, mas sem perder acurácia.

Foi possível desenvolver os três sistemas utilizando o janelamento, tido como o estado da arte para algoritmos de classificação de sinais eletromiográficos. Foi possível identificar, em um primeiro momento, a Floresta Aleatória, dentre os três classificadores, como a melhor ferramenta, além de ter sido possível explorar ainda mais suas competências e capacidades.

Nesse cenário atual, onde a cada dia, novas pessoas necessitam de próteses, e essas possuem custos muito acima da realidade da maioria dos brasileiros, cada vez é mais necessário encontrar soluções nacionais. Os resultados obtidos demonstram como é justamente possível obter resultados em linha, ou por vezes até superiores a aqueles tidos como estado da arte, e ainda melhor, utilizando baixo poder computacional e facilmente embarcável.

Com este trabalho, fica o desafio em saber se a Floresta Aleatória continuará a repetir seu bom desempenho com uma base de dados contendo voluntários amputados, além de ampliar os testes e seu potencial em um trabalho unicamente dedicado a otimizá-la. Os classificadores desenvolvidos podem facilmente ser embarcados em trabalhos futuros, sendo até mesmo vinculados a alguma ferramenta de captura de sinais sEMG para classificações em tempo real.

6.1. Sugestões Para Trabalhos Futuros

- Ampliar os testes comparativos dos três classificadores, utilizando outros bancos de dados, preferencialmente com voluntários amputados. Para tal, sugere-se a utilização do Ninapro DB3.
- Testar os classificadores frente a bancos de dados com maior taxa amostral, para tal, sugere-se a utilização do Ninapro DB2
- Ampliar os testes feitos com a Floresta Aleatória, identificando uma configuração otimizada para melhorar a sua acurácia.
- Testar o comportamento dos classificadores frente a capturas de dados feitos em diferentes dias e horários. Para tal, sugere-se o DB6
- Ampliar os testes comparativos utilizando outras técnicas de classificadores.

- Aprofundar os testes com os diferentes tamanhos de janelamento.
- Aprofundar a análise sobre quais *features* são mais ou menos relevantes para a classificação final.
- Criar um modelo com capacidade para aprendizagem recorrente
- Embarcar um sistema classificador em um microcontrolador ou FPGA e garantir um tempo de classificação viável para uso em uma prótese.

7. REFERÊNCIAS

9 TO 5 MAC. **Apple Watch saves Brazilian man after heart alerts lead to life-threatening tachycardia diagnosis.** Disponível em: <<https://9to5mac.com/2020/01/09/apple-watch-tachycardia-jorge-freire-jr/#:~:text=Freire%20concludes%20that%20the%20Apple,sign%20of%20a%20heart%20attack>>

ACEVEZ-FERNANDEZ, M.A et al. **Methodology Proposal of EMG Hand Movement Classification Based on Cross Recurrence Plots.** Disponível em: <<https://www.hindawi.com/journals/cmmm/2019/6408941/>>

ALL3DP. **Open Bionics Releases Incredibly Affordable and Customizable “Hero Arm” Prosthetic.** Disponível em: <<https://m.all3dp.com/open-bionics-releases-3d-printed-affordable-hero-arm/>>

ANDERSON, Dave; MCNEILL, George. **Artificial neural networks technology.** A DACS State-of-the-Art Report, 1992

ARJAN, Gijsberts. **Measuring Movement Classification Performance with the Movement Error Rate.** IEEE transactions on neural systems and rehabilitation engineering: a publication of the IEEE Engineering in Medicine and Biology Society. 2014.

ATZORI, Manfredo 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, 2015.

ATZORI, Manfredo et al. **Effect of clinical parameters on the control of myoelectric robotic prosthetic hands.** The Journal of Rehabilitation Research and Development 53(3). 2016.

ATZORI, Manfredo et al. **Electromyography data for non-invasive naturally-controlled robotic hand prostheses.** Scientific data, v. 1, p. 140053, 2014.

BIAU, Gérard. **Analysis of a Random Forests Model.** J. Mach. Learn. Res. 13, null (3/1/2012), p. 1063–1095.

BREIMAN, Leo. **Consistency for a simple model of random forests.** Technical Report 670, UC Berkeley, 2004. Disponível em: <<http://www.stat.berkeley.edu/~breiman>>

BREIMAN, Leo; FRIEDMAN, Jerome; STONE, Charles; OLSHEN, R.A.. **Classification and Regression Trees.** Chapman & Hall, New York, 1984.

BUCHANAN, B. G. (2005). **A (Very) Brief History of Artificial Intelligence.** AI Magazine, 26(4), 53.

BUSINESS WIRE. **Mobius Bionics Brings DEKA's LUKE Prosthetic Arm.** Disponível em: <<https://www.businesswire.com/news/home/20160708005511/en/Mobius-Bionics-Bring-DEKA%E2%80%99s-LUKE-Prosthetic-Arm>>

DATA ASPIRANT. **How the random forest algorithm works in machine learning.** Disponível em: <<https://dataaspirant.com/random-forest-algorithm-machine-learning/>>

DIGITAL TRENDS. **Konami built the ultimate prosthetic arm for this gamer, and it has a drone.** Disponível em: <<https://www.digitaltrends.com/cool-tech/prosthetic-arm-boasts-phone-charger-and-drone/>>

DIGITAL TRENDS. **Who needs a prosthetic arm when you can have a steampunk tattoo machine arm instead?** Disponível em: <<https://www.digitaltrends.com/cool-tech/tattoo-gun-prosthetic-arm/>>

EASY EMG: **A Guide to Performing Nerve Conduction Studies and Electromyography** – Jay M. Weiss, Lyn D. Weiss, Julie K. Silver – Second Edition 2016

ESTADAO. **Startup investe em impressão 3d para fabricas próteses de braço mais baratas.** Disponível em: <<https://link.estadao.com.br/noticias/inovacao,startup-investe-em-impressao-3d-para-fabricar-proteses-de-braco-mais-baratas,10000028902>>

FAVIERO, Gabriela Winkler. **Controle de uma prótese experimental do segmento mão-braço por sinais mioelétricos e redes neurais artificiais.** Disponível em: <<https://www.lume.ufrgs.br/bitstream/handle/10183/18554/000730610.pdf?sequence=1>>

FERBA. **Acidentes de trânsito são a segunda maior causa de amputações no Brasil.** Disponível em: <<http://ferba.com.br/2017/09/20/acidentes-de-transito-sao-a-segunda-maior-causa-de-amputacoes-no-brasil/>>

GESTEL, Tony van et al **Benchmarking Least Squares Support Vector Machine Classifiers.** Machine Learning 54, 5–32 (2004). Disponível em: <<https://link.springer.com/article/10.1023/B:MACH.0000008082.80494.e0#citeas>>

HE, Yunan *et al.* **Surface EMG Pattern Recognition Using Long Short-Term Memory Combined with Multilayer Perceptron.** 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2018, pp. 5636-5639, doi: 10.1109/EMBC.2018.8513595.

INDUSTRIAL SAFETY & HYGIENE NEWS. **Statistics on Hand and arm loss.** Disponível em:

<<https://www.ishn.com/articles/97844-statistics-on-hand-and-arm-loss#targetText=existence%20of%20350%2C000%20persons%20with,10%25%20of%20upper%20limb%20population>>

INTERESTING ENGINEERING. **Apple Watch Credited with Saving a UK Dad from Heart Attack, Stroke.** Disponível em: <<https://interestingengineering.com/apple-watch-credited-with-saving-a-uk-dad-from-heart-attack-stroke>>

JARQUE-BOU, Néstor; ATZORI, Manfredo; MÜLLER, Henning. **A large calibrated database of hand movements and grasps kinematics.** Sci Data 7, 12 (2020)

KOVÁLS, Z.L. (1997). **“O cérebro e sua Mente: Uma Introdução a Neurociência Computacional”.** Em: São Paulo, Edição Academia, 215.

KUZBORSKIJ, Ilja; GIJSBERTS, Arjan; CAPUTO, Barbara. **On the challenge of classifying 52 hand movements from surface electromyography.** 2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2012, pp. 4931-4937, doi: 10.1109/EMBC.2012.6347099

LOUPPE, Gilles. **Understanding Random Forests: From Theory to Practice.** PhD dissertation.2014. Disponível em: <<https://arxiv.org/abs/1407.7502v3>>

MASS DEVICE. **Mobius Bionics touts 1st use of DEKA’s LUKE bionic prosthetic arm.** Disponível em: <<https://www.massdevice.com/mobius-bionics-touts-1st-use-dekas-luke-bionic-prosthetic-arm/>>

MCINTOSH, Jess et al. **Practical Hand Gesture Classification with Wrist-Mounted EMG and Pressure Sensing.** Disponível em: < <https://www.frederickerber.de/publications/empress2016.pdf>>

MED DEVICE ONLINE. **DARPA's Mind-Controlled Arm Prosthesis Preps for Commercial Launch.** Disponível em: <<https://www.meddeviceonline.com/doc/darpa-s-mind-controlled-arm-prosthesis-preps-for-commercial-launch-0001>>

MINISTÉRIO DA SAÚDE. **Diretrizes de Atenção à Pessoa Amputada.** Disponível em: <https://bvsms.saude.gov.br/bvs/publicacoes/diretrizes_atencao_pessoa_amputada.pdf>

MIROVSKI, Jonas Miguel Stanislau Beal. **Processamento embarcado de sinais mioelétricos aplicado ao controle de próteses de mão.** Orientador: Prof. Ms. João Olegário de Oliveira de Souza. 2018. Trabalho de Conclusão de Curso – Engenharia Eletrônica. UNISINOS, São Leopoldo.

MOBIUS BIONICS. **LUKE Arm.** Disponível em: <<http://www.mobiusbionics.com/luke-arm/#section-three>>

MOBIUS BIONICS. **LUKE Arm Specs Sheet**. Disponível em:

<<http://www.mobiusbionics.com/wp-content/uploads/2019/09/Mobius-Bionics-LUKE-Product-Spec-Sheet.pdf>>

MOLETA, Patrícia. **Estudo da captação de sinais mioelétricos em instrumentação biomédica**.

Faculdades de Valinhos. Disponível em:

<<https://repositorio.pgsskroton.com.br/bitstream/123456789/980/1/artigo%209.pdf>>

MORAIS, Rafael Lima. **Uso de Árvores Aleatórias para Classificação Sensorial de Arroz Cozido**.

Orientador: Professor Dr. George Freitas von Borries. 2017. Trabalho de Conclusão de Curso – Bacharel em Estatística. UNB, Brasília.

MOREIRA, C. **Neurônio**, Rev. Ciência Elem., V1(01):008. 2013.

NALBAND, Saif; SUNDAR, Aditya; PRINCE, Amalin; AGARWAL, Anita, **Feature selection and classification methodology for the detection of knee-joint disorders**. Computer Methods and Programs in Biomedicine, vol. 127, pp. 94–104, 2016.

OPEN BIONICS. **Hero Arm**. Disponível em:

<<https://openbionics.com/hero-arm/>>

OTTOBOCK. **Body-Powered prosthetic solutions**. Disponível em:

<<https://www.ottobockus.com/prosthetics/upper-limb-prosthetics/solution-overview/body-powered-prosthetic-solutions/>>

PANDOCARE. **Types of Upper Extremity Prostheses**. Disponível em:

<<http://www.pandocare.com/upper-extremity-types/#1471966938595-7757743e-c7b3>>

PEEDEMANN, Bart et al. **Myoelectric forearm prostheses: State of the art from a user-centered perspective**. Journal of rehabilitation research and development. J Rehabil Res Dev. 2011;48(6):719-737. Disponível em: <

<https://pubmed.ncbi.nlm.nih.gov/21938658/>>

QUORA. **How do artificial neural networks work?** Disponível em: <<https://www.quora.com/How-do-artificial-neural-networks-work> >

RAEZ, M. B.; HUSSAIN, M. S.; & MOHD-YASIN, F. **Techniques of EMG signal analysis: detection, processing, classification and applications**. Biological procedures online, 8, 11–35. Disponível em: <

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC1455479/>>

SANTANA, Felipe Bachion. **Floresta Aleatória Para Desenvolvimento De Modelos Multivariados De Classificação E Regressão Em Química Analítica**. Orientador: Prof. Dr. Ronei Jesus Poppi. 2020. Tese de Doutorado – Doutor em Ciências. UNICAMP, Campinas.

SCHUCH, C. M., and C. H. Pritham. 1994. **International standards organization terminology: Application to prosthetics and orthotics**. Journal of Prosthetics and Orthotics 6(1):29-33.

SOCIEDADE BRASILEIRA DE ANÁLISES CLÍNICAS. **Qual a situação da diabetes no Brasil?** Disponível em:

<<http://www.sbac.org.br/blog/2018/11/26/qual-a-situacao-da-diabetes-no-brasil/#targetText=A%20Organiza%C3%A7%C3%A3o%20Mundial%20da%20Sa%C3%BAde,aos%20108%20milh%C3%B5es%20de%201980.>>

TATARIAN, Karen et al. **Stepping-stones to Transhumanism: An EMGcontrolled Low-cost Prosthetic Hand for Academia**. 2018 International Conference on Intelligent Systems (IS), Funchal - Madeira, Portugal, 2018, pp. 807-812

TOWARDS DATA SCIENCE. **Understanding Neural Networks**. Disponível em:
<<https://towardsdatascience.com/understanding-neural-networks-19020b758230>>

VIAS SEGURAS. **Estatísticas nacionais de acidentes de trânsito**. Disponível em:
<http://vias-seguras.com/os_acidentes/estatisticas/estatisticas_nacionais>

VICARIO, Sergio A. Vasquez; OUBRAM, Outmane; BASSAM, A.. **Intelligent Recognition System of Myoelectric Signals of Human Hand Movement**. Intelligent Computing Systems (pp.97-112). 2018

VILLOSLADA, Alvaro. **Design and implementation of a myoelectric Control system for a printable robotic hand**. Thesis for: Master of Science. 2012

WIRTA, Roy; TAYLOR, Donald; FINLEY, Ray. **Pattern-recognition arm prosthesis: a historical perspective — a final report**. Bulletin of Prosthetics Research—Fall 1978. Disponível em:
<<https://pdfs.semanticscholar.org/55c2/50e65f1849786b182d17d18f6a857a85babb.pdf>>