



UNIVERSIDADE FEDERAL DA BAHIA
ESCOLA POLITÉCNICA
PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**REDES NEURAS ARTIFICIAIS APLICADAS À CLASSIFICAÇÃO DE GESTOS
DA MÃO ATRAVÉS DE SINAIS ELETROMIOGRÁFICOS**

MICHELLE GUSMÃO BURGOS DA FONSECA

ORIENTADOR: PROF. DR. ANDRÉ GUSTAVO SCOLARI CONCEIÇÃO

COORIENTADOR: PROF. DR. EDUARDO FURTADO DE SIMAS FILHO

Salvador - BA
Fevereiro de 2019

UNIVERSIDADE FEDERAL DA BAHIA
ESCOLA POLITÉCNICA
PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**REDES NEURAIS ARTIFICIAIS APLICADAS À CLASSIFICAÇÃO DE GESTOS
DA MÃO ATRAVÉS DE SINAIS ELETROMIOGRÁFICOS**

MICHELLE GUSMÃO BURGOS DA FONSECA

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal da Bahia, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. André Gustavo Scolari
Conceição
Coorientador: Prof. Dr. Eduardo F. de Simas
Filho

Salvador- BA
Fevereiro de 2019

Ficha catalográfica elaborada pelo Sistema Universitário de Bibliotecas (SIBI/UFBA),
com os dados fornecidos pelo(a) autor(a).

Fonseca, Michelle Gusmao Burgos da Fonseca
Redes Neurais Artificiais Aplicadas a Classificação
de gestos da Mão Através de Sinais Eletromiográficos /
Michelle Gusmao Burgos da Fonseca Fonseca. --
Salvador, 2019. --
98 f. : il

Orientador: Prof. DR. Andre Gustavo Scolari
Conceição Conceição.
Coorientador: Prof. Dr. Eduardo F. de Simas Filho
Simas Filho.
Dissertação (Mestrado - Engenharia Eletrica) --
Universidade Federal da Bahia, UFBA, 2019.

1. Redes neurais artificiais. 2. Sinais
eletromiográficos. 3. Reconhecimento e classificação
de gestos. I. Conceição, Prof. DR. Andre Gustavo
Scolari Conceição. II. Simas Filho, Prof. Dr. Eduardo
F. de Simas Filho. III. Título.

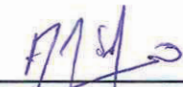
Michelle Gusmão Burgos da Fonseca

Redes Neurais Aplicadas ao Reconhecimento e classificação de gestos da mão baseada em sinais Eletromiográfico (EMG)

Dissertação apresentada à Universidade Federal da Bahia, como parte das exigências do Programa de Pós-Graduação em Engenharia Elétrica, para a obtenção do título de *Mestre*.

APROVADA em: 18 de Fevereiro de 2019.

BANCA EXAMINADORA



Prof. Dr. André Gustavo Scolari Conceição
Orientador - UFBA



Prof. Dr. Eduardo Furtado de Simas Filho
UFBA



Prof. Dr. Fabrício Gerônimo Simões Silva
UFBA



Prof. Dr. Antônio Carlos Lopes Fernandes Junior
UFBA

Um homem precisa viajar. Por sua conta, não por meio de histórias, imagens, livros ou TV. Precisa viajar por si, com seus olhos e pés, para entender o que é seu. Para um dia plantar as suas próprias árvores e dar-lhes valor. Conhecer o frio para desfrutar o calor. E o oposto. Sentir a distância e o desabrigo para estar bem sob o próprio teto. Um homem precisa viajar para lugares que não conhece para quebrar essa arrogância que nos faz ver o mundo como o imaginamos, e não simplesmente como é ou pode ser. Que nos faz professores e doutores do que não vimos, quando deveríamos ser alunos, e simplesmente ir ver.

Amir Klink

Agradecimentos

Agradeço à minha família, em especial à minha mãe Ana Cristina, por todo seu carinho, dedicação e incentivo, sem ela eu nada seria. À minha tia Thereza, por toda ajuda, incentivo e acreditar em mim quando nem mesmo eu estava acreditando.

Aos meus orientadores, em especial ao Prof. Eduardo Simas, pelo incentivo, por me nortearem e me apresentarem pessoas que caminharam comigo nessa jornada. Ao professor Fernando Moreira, por todo apoio, paciência e palavra amiga.

Aos amigos que fiz nessa jornada Pedro Aurélio, Uziel e, em especial, ao Edmar Egídio, que tanto me ajudou, me ensinou, incentivou e por todas as conversas de apoio.

Aos meus amigos, em especial, àqueles que me deram forças para seguir quando pensei que não poderia continuar, pelos tantos momentos de conversa, distrações para desopilar, por me motivarem e por compreenderem as minhas ausências, pelas palavras positivas e por confiarem em mim.

À FAPESB pelo suporte financeiro.

Minha eterna gratidão a todos aqueles que de alguma forma influenciaram para que eu pudesse chegar até aqui, que me ajudaram a superar os momentos difíceis, que caminharam comigo, que me deram apoio e não deixaram que eu desistisse, por me apresentarem uma nova visão da vida, por me ensinarem tanto todos os dias.

Gratidão!

Resumo da Dissertação apresentada ao PPGEE/UFBA como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica.

REDES NEURAIS ARTIFICIAIS APLICADAS À CLASSIFICAÇÃO DE GESTOS DA MÃO ATRAVÉS DE SINAIS ELETROMIOGRÁFICOS

MICHELLE GUSMÃO BURGOS DA FONSECA

Fevereiro/2019

Orientadores: André Gustavo Scolari Conceição

Eduardo F. de Simas Filho

Este trabalho visa o reconhecimento e classificação dos gestos da mão a partir de sinais eletromiográficos (EMG) obtidos através de uma braçadeira Myo®, que possui oito eletrodos de classe médica. Cada eletrodo fornece uma informação referente à contração muscular realizada na execução do movimento. Esses sinais serão processados para a obtenção de uma “assinatura” padrão para possibilitar o treinamento da rede neural artificial (RNA). Essas assinaturas serão extraídas para cada tipo de movimento e, em seguida, um método de mapeamento adequado é aplicado para classificar os sinais EMG. É realizada uma comparação entre os algoritmos *Resilient Backpropagation* (Rprop) e *Levenberg-Marquardt* (LM) em todos os conjuntos de dados treinados. Foram escolhidos cinco movimentos para classificação e utilizados conjuntos de dados com até sete características. Dentre os 144 testes executados, o melhor resultado obtido foi de 88,2% com o Rprop e de 88,4% com o LM. Porém, de forma geral, o algoritmo Rprop apresentou melhor desempenho na maioria dos testes, quando comparado ao LM, sendo o tempo de treinamento a diferença mais significativa entre ambos. Espera-se com esse trabalho expandir as pesquisas na área de Tecnologia Assistiva (TA) para conquistar formas alternativas de inclusão social e melhorar a autonomia de pessoas com deficiência ou mobilidade reduzida dos membros superiores.

Palavras-chave: Redes neurais artificiais, sinais eletromiográficos, reconhecimento e classificação de gestos.

Abstract of Dissertation presented to PPGEE/UFBA as a partial fulfillment of the requirements for the degree of Master in Electrical Engineering.

ARTIFICIAL NEURAL NETWORKS APPLIED TO THE CLASSIFICATION OF HAND GESTURES THROUGH ELECTROMIOGRAPHIC SIGNS

MICHELLE GUSMÃO BURGOS DA FONSECA

February/2019

Advisors: André Gustavo Scolari Conceição

Eduardo F. de Simas Filho

This project aims the recognition and classification of hand gestures using electromyographic signals (EMG) obtained through a Myo® armband, which has eight medical electrodes. Each electrode provides signal information regarding muscle contraction performed in the execution of the movement. These signals will be processed to obtain a standard "signature" to enable artificial neural network (ANN) training. These signatures will be extracted for each type of movement, and then a suitable mapping method is applied to classify the EMG signals. A comparison between the Resilient Backpropagation (Rprop) and Levenberg-Marquardt (LM) algorithms is performed on all trained datasets. Five motions were chosen for classification and data sets with up to seven characteristics were used. Among the 144 tests performed, the best result was 88.2% to Rprop and 88.4% to LM. However, in general, the Rprop algorithm presented better performance in most of the tests when compared to LM, the training time being the most significant difference between both. This work is expected to expand research in the area of Assistive Technology (AT) to achieve alternative forms of social inclusion and improve the autonomy of people with disabilities or reduced mobility of the upper limbs.

Keywords: *Artificial neural networks, electromyographic signals, recognition and classification of gestures.*

LISTA DE FIGURAS

Figura 2.1 – Exemplos de Tecnologias Assistivas: a) e b) adaptadores. c) rampa de acesso. d) prótese robótica de membro superior.	19
Figura 2.2 – Representação de uma unidade motora.	22
Figura 2.3 – Estrutura do músculo esquelético.	23
Figura 2.4 – Representação de duas UMs propagando MUAPs e a captura do sinal sEMG.	23
Figura 2.5 – Eletrodo invasivo: tipo agulha.	25
Figura 2.6 – Eletrodo de superfície.	26
Figura 2.7 – Configuração do eletrodo em modo monopolar.	27
Figura 2.8 – configuração do eletrodo em modo bipolar.	28
Figura 2.9 – Amplitude e frequência do sinal EMG em relação ao posicionamento de eletrodos.....	30
Figura 2.10 – Exemplo Sinal eletromiográfico proveniente de uma contração isométrica do tríceps.	34
Figura 2.11 – Braçadeira Myo® e a ordem dos sensores.	35
Figura 2.12 – Movimentos de ‘Fist’, ‘Fingers Spread’, ‘Wave In’, ‘Wave Out’ e ‘Double Tap’ respectivamente.	37
Figura 3.1 – Neurônio Biológico.	40
Figura 3.2 – Neurônio de McCulloch.	40
Figura 3.3 – Representação do Neurônio Artificial.	41
Figura 3.4 – RNA de uma única camada.	42
Figura 3.5 – RNA multicamada.	42
Figura 3.6 – RNA <i>Feedforward</i>	43
Figura 3.7 – RNA <i>Feedback</i>	43
Figura 3.8 – Exemplo de rede MLP.....	44
Figura 4.1 – Diagrama de blocos do processo de reconhecimento de gestos.	51
Figura 4.2 – Classes de Movimento. a) Desvio Radial b) Desvio Ulnar c) Mão Fechada d) Mão com Bola e) Mão com <i>Gripper</i>	51
Figura 4.3 – Exemplo de Sinal EMG para teste (Mão com <i>Gripper</i>).	52
Figura 4.4 – Exemplo de 2 gráficos ROC.....	56

Figura 4.5 – Exemplo de Matriz de Confusão	58
Figura 4.6 – Tela de treinamento da rede neural: divisão dos subconjuntos.	59
Figura 4.7 – Tela de treinamento da rede neural: Resultado.	60
Figura 4.8 – Tela de treinamento da rede neural: Melhor treino.....	61
Figura 5.1 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto com Todas as características – 15NH – 500 épocas.	64
Figura 5.2 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto com Todas as características – 15NH – 500 épocas.	64
Figura 5.3 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem a característica MAV – 15 NH – 1000 épocas.	66
Figura 5.4 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem a característica MAV – 15 NH – 1000 épocas.	66
Figura 5.5 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem a característica RMS – 15NH – 500 épocas.....	67
Figura 5.6 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem a característica RMS – 15NH – 500 épocas.....	68
Figura 5.7 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem a característica VAR – 15 NH – 500 épocas.	69
Figura 5.8 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem a característica VAR – 15 NH – 500 épocas.	69
Figura 5.9 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem a característica WL – 15 NH – 1000 épocas.	71
Figura 5.10 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem a característica WL – 15 NH – 1000 épocas.....	71
Figura 5.11 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem ZC – 15NH – 1000 épocas.....	72
Figura 5.12 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem ZC – 15NH – 1000 épocas.....	73
Figura 5.13 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem a característica SSC – 15 NH – 500 épocas.....	74
Figura 5.14 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem a característica SSC – 15 NH – 500 épocas.....	74

Figura 5.15 - Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem a característica WA – 15 NH – 500 épocas.	75
Figura 5.16 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem a característica WA – 15 NH – 500 épocas.	76
Figura 5.17 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem as características WL e SSC – 10 NH – 500 épocas.....	77
Figura 5.18 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem as características WL e SSC – 10 NH – 500 épocas.	77
Figura 5.19 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem as características WL e WA – 15 NH – 1000 épocas: melhor resultado.	79
Figura 5.20 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem as características WL e WA – 15 NH – 1000 épocas: melhor resultado.....	79
Figura 5.21 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem as características RMS, SSC e WA – 5 NH – 500 épocas.....	81
Figura 5.22 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem as características RMS, SSC e WA – 5 NH – 500 épocas.	81
Figura 5.23 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem as características RMS, SSC e WA – 5 NH – 500 épocas.....	82
Figura 5.24 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem as características RMS, SSC e WA – 5 NH – 500 épocas.	82
Figura 5.25 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem as características RMS, WL e ZC – 10 NH – 500 épocas.....	84
Figura 5.26 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem as características RMS, WL e ZC – 10 NH – 500 épocas: melhor resultado.....	84
Figura 5.27 – Matriz de confusão do conjunto sem RMS, SSC e WA – 15NH – 500 épocas.....	86

Lista de Tabelas

Tabela 4.1 – Exemplo da extração de características dos dados brutos para o movimento Mão com <i>Gripper</i> normalizados ente 0 e 1.	53
Tabela 5.1 – Grupos com as características para alimentação dos classificadores..	62
Tabela 5.2 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto com Todas as características.	63
Tabela 5.3 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem a característica MAV.	65
Tabela 5.4 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem a característica RMS.	67
Tabela 5.5 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem a característica VAR.	68
Tabela 5.6 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem a característica WL.	70
Tabela 5.7 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem a característica ZC.	72
Tabela 5.8 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem a característica SSC.	73
Tabela 5.9 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem a característica WA.	75
Tabela 5.10 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem as características WL e SSC.	76
Tabela 5.11 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem as características WL e WA.	78
Tabela 5.12 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem as características RMS, SSC e WA.	80
Tabela 5.13 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem as características RMS, WL e ZC.	83
Tabela 5.14 – Resumo entre o melhor e o pior desempenho por grupo.	85

LISTA DE SÍMBOLOS E ABREVIATURAS

SÍMBOLOS

ACh	Acetilcolina
Ag	Prata
AgCl	Cloreto de Prata
Ca²⁺	Cátion divalente de Cálcio
Hz	Hertz
K⁻	Ânion monovalente de Potássio
K⁺	Cátion monovalente de Potássio
kHz	Kilo Hertz ou 10 ³ Hertz
kΩ	Kilo Ohm ou 10 ³ Ohm
mAh	Mili Âmpere hora ou 10 ⁻³ Âmpere hora
mV	Mili Volts ou 10 ⁻³ Volts
Na⁺	Cátion monovalente de Sódio
Na²⁺	Cátion divalente de Sódio
nArms	Nano Âmpere RMS ou 10 ⁻⁹ Âmpere RMS
pArms	Pico Âmpere RMS ou 10 ⁻¹² Âmpere RMS
pH	Potencial Hidrogênico
μV	Micro Volts ou 10 ⁻⁶ Volts
Σ	Somatório
Ω	Ohm
Δ_{ij} (t)	Atualização do valor de variação do peso

ABREVIATURAS

ADC	<i>Analog Digital Converter</i>
AR	Autorregressivo
BP	<i>Backpropagation</i>
EMG	Eletromiografia
FN	Falso Negativo
FP	Falso Positivo
IAC	Inteligência Artificial Conexionista
IAS	Inteligência Artificial Simbólica
IAV	<i>Integrated Absolute Value</i>
IMU	<i>Inertial Measurement Unit</i>
KNN	<i>K-Nearest Neighbor</i>
LDA	<i>Linear Discriminant Analysis</i>
LED	<i>Light Emitting Diode</i>
LM	<i>Levenberg-Marquardt</i>
MAV	<i>Mean Absolute Value</i>
MLP	<i>Multilayer Perceptron</i>
MUAP	<i>Motor Unit Action Potential</i>
PA	Ponteciais de Ação
PD	Probabilidade de Detecção
PE	Produto das Eficiências
PE	Produto das Eficiências
RBP	<i>Resilient Backpropagation</i>
RMS	<i>Root Mean Square</i>
RNA	Redes Neurais Artificiais
ROC	<i>Receiver Operator Characteristic</i>
Rprop	<i>Resilient Backpropagation</i>

sEMG	EMG de Superfície
SNC	Sistema Nervoso Central
SSC	<i>Slope Sign Change</i>
SVM	<i>Support Vector Machine</i>
TA	Tecnologia Assistiva
TFP	Taxa de Falso Positivo
TVP	Taxa de Verdadeiro Positivo
UM	Unidade Motora
VAR	Variância
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo
WA	<i>Willison Amplitude</i>
WL	<i>Waveform Length</i>
ZC	<i>Zero Crossing</i>

SUMÁRIO

1. INTRODUÇÃO.....	13
1.1 Motivação.....	14
1.2 Objetivos.....	15
1.2.1 Os objetivos específicos deste trabalho são:.....	15
1.3 Organização do Trabalho.....	15
2. INTRODUÇÃO À TECNOLOGIA ASSISTIVA E AOS SINAIS ELETROMIOGRÁFICOS	17
2.1 Tecnologia Assistiva	17
2.2 Sinais Eletromiográficos.....	19
2.2.1 Contração Muscular.....	21
2.2.2 Tipos de Eletrodos.....	24
2.2.3 Fatores que afetam o sinal e a intensidade do EMG Produzido por um músculo	29
2.2.4 Impedância e ruído do sinal EMG.....	31
2.2.5 Sensor Myo®.....	34
3. REDES NEURAIS ARTIFICIAIS - RNA.....	39
3.1 O Modelo de McCulloch e Pitts	39
3.2 Arquitetura das Redes Neurais Artificiais.....	41
3.2.1 Rede Multilayer Perceptron – MLP	44
3.3 Algoritmo de Treinamento.....	44
3.3.1 <i>Resilient Backpropagation</i>	44
3.3.2 <i>Levenberg-Marquardt</i>	46
3.3 Processo de Reconhecimento de Padrões	47
4. METODOLOGIA E DESENVOLVIMENTO DO TRABALHO	50
4.1 Métricas de Avaliação de Desempenho.....	50
4.1.1 Aquisição de Sinais	51
4.1.2 Reconhecimento de Padrão de Gestos.....	53
4.1.3 Produto das Eficiências.....	55

4.1.4	Curva ROC.....	55
4.1.5	Matriz de Confusão	57
4.1.6	Treinamento das RNA.....	59
5.	RESULTADOS	62
5.1	Análise dos Resultados	84
6.	CONCLUSÕES.....	87
6.1	Trabalhos Futuros	88
	REFERÊNCIAS.....	89
	APÊNDICE A	97
A-1	Artigos em Congressos	97

Capítulo 1

1. INTRODUÇÃO

O desenvolvimento de técnicas de processamento de sinais e inteligência artificial tem contribuído significativamente para avanços em diversas áreas do conhecimento. A utilização de processamento estatístico de sinais tem sido a solução de muitos problemas e passou a fazer parte de diversas aplicações, como por exemplo, o tratamento de sinais biomédicos, as previsões através de sinais sísmicos e redução de falhas em telecomunicações (AHSAN, 2011).

Atualmente, acessibilidade e inclusão social são temas que têm sido discutidos frequentemente. O termo Tecnologia Assistiva (TA), abrange não apenas produtos, mas qualquer método que tenha o objetivo de facilitar a vida cotidiana das pessoas com mobilidade reduzida, podendo ser serviços, estratégias, tecnologias ou recursos.

Devido ao avanço tecnológico, a área de robótica tem deixado de ser um recurso somente das indústrias e tem expandido suas aplicações para diversas áreas, passando a ser componente importante na área médica (em cirurgias complexas), em segurança (realizando tarefas perigosas), em residências (no auxílio de tarefas domésticas), e também, tem-se adaptado essa tecnologia para trazer benefícios às pessoas com necessidades especiais (AZEVEDO, 2015).

Uma série de pesquisas têm sido realizadas na aplicação dos sinais eletromiográficos (EMG) para a interação com máquinas (AHSAN, 2011). O propósito para a realização de reconhecimento de gestos é a criação de um sistema que possa identificar gestos humanos específicos e usá-los para transmitir informações ou controlar dispositivos diversos.

Conforme Atzori et al. (2016), atualmente, existem próteses mioelétricas avançadas do ponto de vista mecânico e capazes de realizar diversos movimentos, porém os métodos de controle ainda deixam a desejar. Muitas próteses de mão já estão disponíveis, porém poucas tem a capacidade de realizar muitos movimentos diferentes, além do alto custo.

O desenvolvimento de controle baseado nos sinais EMG é de suma importância e traz como benefício o aumento da autonomia e aceitação social das pessoas com deficiência ou mobilidade reduzida, melhorando sua qualidade de vida. No entanto, a parte mais difícil para o desenvolvimento de interfaces com controle mioelétrico é o

reconhecimento de padrões de sinais EMG. Isto é devido às grandes variações em sinais EMG, existindo diferentes assinaturas para gestos semelhantes, dependendo da idade, atividade dos músculos, camada de gordura da pele e estilo de execução do gesto.

Este trabalho propõe a classificação dos sinais eletromiográficos do usuário baseado no treinamento de redes neurais artificiais para reconhecimento de gestos da mão, obtidos através de uma braçadeira Myo®, que possui sensores de eletromiografia e sensores inerciais embarcados. Utiliza-se a comparação de desempenho de dois algoritmos de redes neurais artificiais - RNA, *Backpropagation* e *Levenberg-Marquardt*.

1.1 Motivação

A acessibilidade é um tema que tem sido abordado com bastante frequência no atual cenário social, onde empresas e governo estão realizando ações e políticas públicas para incluir pessoas com necessidades especiais e tornar sua vida mais fácil. Transformações crescentes no âmbito tecnológico, científico e social, propiciaram o ganho de visibilidade da TA entre os pesquisadores que, por sua vez, vislumbram o aproveitamento desse crescimento tecnológico para possibilitar autonomia e inclusão social às pessoas com necessidades especiais.

No contexto da Robótica é possível aliar movimentos robóticos aos movimentos humanos, sendo essa área chamada de Robótica Assistiva e de Reabilitação. Ela tem se tornado área de interesse de pesquisa devido à capacidade dos dispositivos e sensores, que proporcionam melhor resolução e precisão, alta repetibilidade e desempenho auxiliarem na criação de novos dispositivos capazes de proporcionar maiores avanços na área de reabilitação de pessoas com necessidades especiais.

As pesquisas em Robótica Assistiva e suas aplicações exigem abordagens orientadas por humanos (*human-oriented approaches*), pois os dispositivos estão conectados a eles. A consideração dos aspectos técnicos e humanos é fundamental, ou seja, aspectos de ciências humanas devem ser considerados, além de métodos de engenharia. Também devem ser considerados aspectos como a segurança, funcionalidade, eficácia e aceitação que exigem a colaboração multidisciplinar de áreas como *design*, mecatrônica, informática, biomecânica, neurociência e psicologia.

O controle de um periférico ou dispositivo externo pode ser realizado através da identificação dos comandos de movimento a partir de sinais EMG. Para isto, as

assinaturas padrão do sinal EMG são extraídas para cada tipo de movimento e, em seguida, um método de mapeamento adequado pode ser aplicado para classificar os sinais de EMG. Tem sido verificado que o uso de diferentes tipos de RNA tornou-se popular entre os pesquisadores de biosinais (AHSAN, 2011). Isso é devido à sua capacidade de aprendizagem a partir de exemplos e de reproduzir funções não lineares arbitrárias de entrada. A estrutura altamente paralela e regular das RNA as tornam especialmente adequada para tarefas de classificação de padrão (SUBASI et al., 2006).

1.2 Objetivos

Realizar o reconhecimento e classificação de gestos da mão através do treinamento de redes neurais artificiais com sinais eletromiográficos de entrada obtidos a partir de uma braçadeira Myo® com aplicação voltada à Tecnologia Assistiva.

1.2.1 Os objetivos específicos deste trabalho são:

- ❖ Coletar dados dos sinais mioelétricos para cinco gestos diferentes em pessoas com características distintas;
- ❖ Adquirir “assinaturas” para cada gesto;
- ❖ Comparar o desempenho dos algoritmos *Backpropagation* e *Levenberg-Marquadt* utilizados em treinamento de redes neurais artificiais;
- ❖ Utilizar como máquina de aprendizado uma rede *Multi-Layer Perceptron* (MLP);
- ❖ Contribuir com pesquisas na área da robótica e inteligência artificial voltada à tecnologia assistiva;
- ❖ Divulgação da pesquisa em eventos científicos da área.

1.3 Organização do Trabalho

No Capítulo 2 é apresentada uma contextualização sobre os sinais Eletromiográficos e a Tecnologia Assistiva. O Capítulo 3 apresenta os fundamentos teóricos das técnicas de processamento de sinais utilizadas para o reconhecimento de padrões e treinamento de redes neurais artificiais. O Capítulo 4 aborda a metodologia utilizada no projeto desde a realização dos testes para aquisição dos sinais até os treinamentos realizados com as informações coletadas. O Capítulo 5

abrange os dados coletados e os resultados dos experimentos, respectivamente. Por fim, o Capítulo 6 encerra o trabalho com as conclusões e perspectivas para a continuação da pesquisa.

Capítulo 2

2. INTRODUÇÃO À TECNOLOGIA ASSISTIVA E AOS SINAIS ELETROMIOGRÁFICOS

2.1 Tecnologia Assistiva

A Tecnologia Assistiva (TA) é um termo utilizado para identificar recursos e serviços que contribuem para proporcionar ou ampliar habilidades funcionais de pessoas com deficiência e conseqüentemente promover vida independente e inclusão (BERSCH, 2013).

Segundo Brasil (2009) o Comitê de Ajudas Técnicas define a Tecnologia Assistiva da seguinte maneira:

“Tecnologia Assistiva é uma área do conhecimento, de característica interdisciplinar, que engloba produtos, recursos, metodologias, estratégias, práticas e serviços que objetivam promover a funcionalidade, relacionada à atividade e participação, de pessoas com deficiência, incapacidades ou mobilidade reduzida, visando sua autonomia, independência, qualidade de vida e inclusão social.” (BRASIL, 2009).

Outro termo sinônimo à Tecnologia Assistiva é o termo Ajudas Técnicas, que sofreu uma expansão em seu significado quando comparados os Decretos nº 3.298 de 1999 com o nº 5.296 de 2004, para o primeiro:

“Consideram-se ajudas técnicas, para os efeitos deste Decreto, os elementos que permitem compensar uma ou mais limitações funcionais motoras, sensoriais ou mentais da pessoa portadora de deficiência, com o objetivo de permitir-lhe superar as barreiras da comunicação e da mobilidade e de possibilitar sua plena inclusão social” (BRASIL, 1999).

Já o segundo:

“Consideram-se ajudas técnicas os produtos, instrumentos, equipamentos ou tecnologia adaptados ou especialmente projetados para melhorar a funcionalidade da pessoa portadora de deficiência ou com

mobilidade reduzida, favorecendo a autonomia pessoal, total ou assistida” (BRASIL, 2004).

Portugal (2014) através do Catálogo Nacional de Ajudas Técnicas torna ainda mais ampla a definição do termo Ajudas Técnicas:

“Entende-se por ajudas técnicas qualquer produto, instrumento, estratégia, serviço e prática utilizada por pessoas com deficiência e pessoas idosas, especialmente, produzido ou geralmente disponível para prevenir, compensar, aliviar ou neutralizar uma deficiência, incapacidade ou desvantagem e melhorar a autonomia e a qualidade de vida dos indivíduos” (PORTUGAL, 2014).

Nessa expansão é possível verificar que as Ajudas Técnicas ou Tecnologias Assistivas não se limitam a um produto-objeto, mas incluem recursos, serviços, estratégias, tecnologias e práticas que agreguem benefícios a essas pessoas, visando sempre o bem-estar da pessoa deficiente ou incapaz de realizar algumas tarefas, tornando-as mais independentes, com melhor qualidade de vida e fazendo com que se sintam mais incluídas na sociedade.

Conforme a pesquisa realizada pelo Instituto Brasileiro de Geografia e Estatística no censo demográfico de 2010, apresentou-se que o País possui 45,6 milhões de pessoas com alguma deficiência, o que representa 23,9% da população sendo que, “A deficiência foi classificada pelo grau de severidade de acordo com a percepção das próprias pessoas entrevistadas sobre suas funcionalidades” (BRASIL, 2012). A deficiência visual apresentou maior ocorrência (18,6% da população brasileira), seguida pela deficiência motora (7% da população), deficiência auditiva (5,1%) e deficiência mental ou intelectual (1,40%). Porém, o foco principal das políticas públicas é o segmento das pessoas que possuem grau de deficiência severa. A partir dessa pesquisa, realizada em 2010, chegou-se a conclusão de que 8,3% da população brasileira possui pelo menos um tipo de deficiência severa, 3,46% com deficiência severa visual, 2,33% com deficiência severa motora, 1,4% com deficiência mental ou intelectual e 1,12% com deficiência auditiva severa. Logo, é possível verificar que a maior incidência está na deficiência visual seguida pela deficiência motora. A Região Nordeste teve a maior taxa de prevalência de pessoas com pelo menos uma das deficiências (26,63%), seguida pela Região Norte (23,4%). Baseando-se nesses números, pode-se dizer que existe grande demanda para o desenvolvimento de tecnologia assistiva, inserção do tema da TA nos cursos de formação profissional, organização de serviços específicos e ações governamentais

de concessão de TA que atendam a grande demanda reprimida. Esta tecnologia será de grande relevância para a promoção da inclusão das pessoas com deficiência, tanto no campo da educação, inserção no trabalho como na vida em sociedade e na realização pessoal.

Conforme as definições de TA, pode-se considerar como exemplos (Figura 2.1): rampas de acesso, órteses e próteses, dispositivos de auxílio que diminuem o impacto da disfunção física (bengala, andador, barra de apoio, cadeiras de rodas, tapete antiderrapante), adaptadores para dispositivos de alimentação, higiene e vestuário (exemplo, esponja com cabos alongados), softwares para facilitar a comunicação dentre tantos outros dispositivos.

Figura 2.1 – Exemplos de Tecnologias Assistivas: a) e b) adaptadores. c) rampa de acesso. d) prótese robótica de membro superior.



Fonte: Educadores (2018), Clínica de desenvolvimento (2018), Geotrilhas (2012) e Inovação Tecnológica (2018).

2.2 Sinais Eletromiográficos

Os sinais Mioelétricos ou Eletromiográficos foram observados pela primeira vez em 1791 pelo cientista Luigi Galvani em sapos. Conceitualmente, fora descoberto como sendo a representação do “reflexo involuntário da passagem de corrente elétrica pelas fibras musculares” durante contrações por Frenchman Dubois-Reymond em 1849. No século XX, devido ao interesse de pesquisadores por este assunto, surgiu a eletromiografia (EMG), na qual eram utilizados tubos catódicos e eletrodos específicos que, ligados a um osciloscópio, permitiam a visualização dos sinais. A partir do aperfeiçoamento e pesquisas na área, este método já evoluiu bastante,

compreendendo eletrônica analógica, digital e microprocessadores capazes de fornecer melhor precisão (FAVIEIRO, 2009).

EMG é uma técnica eletro-diagnóstica para avaliar e registrar a atividade elétrica produzida pelos músculos esqueléticos humanos. O sinal EMG detecta o potencial elétrico gerado pelas células musculares quando estas células são eletricamente ou neurologicamente ativadas (MeSH, 2016). Segundo Ahsan (2011), também pode ser definido como a medição da atividade elétrica muscular e usualmente representado com uma função do tempo, definido em termos de amplitude, frequência e fase.

Os mesmos eletrodos são utilizados tanto para eletromiografia (sinais dos músculos), quanto para eletroencefalografia (sinais cerebrais) e eletrocardiografia (sinais do coração) (BERNARDES et al., 2007).

Este sinal é extremamente complexo, sendo afetado pelas propriedades anatômicas e fisiológicas dos músculos, pelo esquema de controle do sistema nervoso periférico, bem como pelas características dos instrumentos que são usados para detectá-lo e observá-lo. (ANDRADE, 2000). Além do que, a complexidade do ruído do sinal EMG é maior do que em outros sinais biológicos, e também podem sofrer interferência de outros equipamentos e radiação eletromagnética no momento da aquisição (MANE et al., 2015).

Possui natureza complexa e altamente não-linear, o que torna difícil a relação entre os sinais medidos e um comando para um movimento (MANE et al., 2015). O sinal obtido através dos sensores possui pequena amplitude, sendo necessário tratar esta saída antes que se possa processar o sinal através de um circuito analógico ou digital (DE LUCA, 2002). Para isso são necessários circuitos condicionadores de sinais específicos para cada tipo de sinal e sensor.

Devido ao fato de os movimentos da mão serem executados por vários músculos localizados no antebraço, o uso dos sinais mioelétricos se tornou uma boa opção para realização de controle de uma prótese de mão. Vale ressaltar, que os sinais destes músculos, que realizariam um movimento similar na mão natural, podem ser utilizados para comandar a prótese, tornando mais fácil a adaptação do usuário (ORTOLAN, 2002).

2.2.1 Contração Muscular

Na realização da contração muscular ocorrem diversos processos, começando pela condução de um impulso nervoso pelo neurônio motor, seguido pela transmissão sináptica e dos potenciais de ação do músculo, no qual a soma deles representam o sinal mioelétrico. Por último ocorre a contração das fibras musculares, gerando o movimento dos músculos (MARIEB et al., 2006).

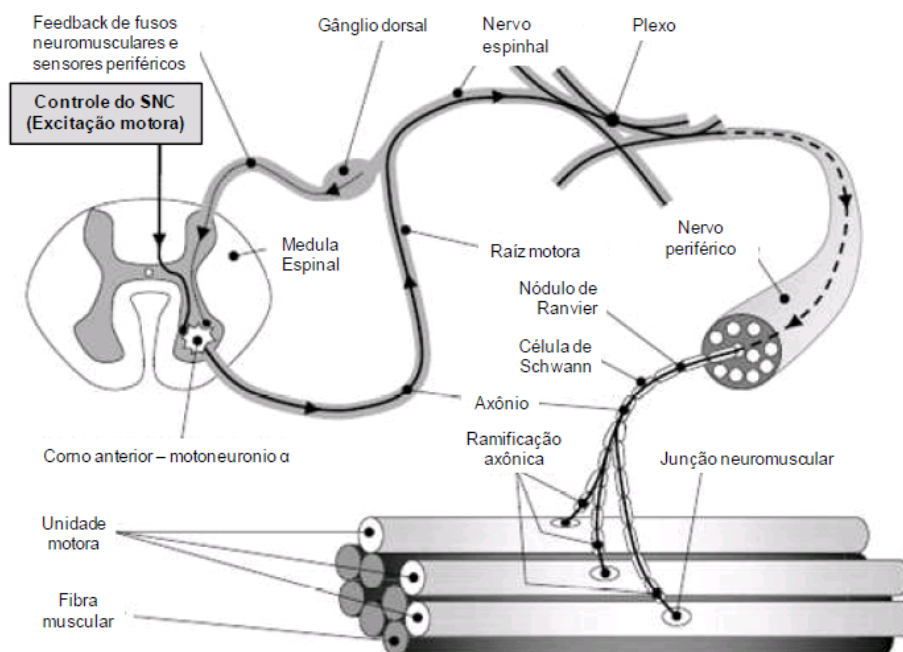
Dois tipos de sinais podem ser gerados pelos neurônios, também conhecidos como células nervosas. O primeiro tipo compreende os Potenciais de Ação (PA), que são encontrados em neurônios motores e propagam o impulso nervoso nos neurônios, caracterizado por variações do potencial elétrico ao longo da membrana celular (MARIEB, 2006; ALMEIDA, 2012). Existem também os potenciais graduados, atenuados de acordo com a distância que percorrem, podem ser encontrados em neurônios sensores e tem por objetivo ativar ou inibir os potenciais de ação.

O Sistema Nervoso Central – SNC regula a força exercida por um músculo durante uma contração através de dois mecanismos: o número de Unidades Motoras - UM recrutadas e a modulação da taxa de disparos de PAs de cada UM (LOEB; GHEZ, 2000).

O neurônio motor, normalmente encontrado no Sistema Nervoso Central, é composto pelo corpo celular, dendritos e um axônio. O corpo celular é localizado na medula espinhal e suas terminações axônicas inervam fibras musculares, formando uma região conhecida como junção neuromuscular ou placa motora (ALMEIDA, 2012). Ele engloba um núcleo e um nucléolo bem definido, enquanto os dendritos são geralmente pequenas extensões citoplasmáticas espessas e altamente ramificadas, que recebem os impulsos elétricos e os conduzem em direção ao corpo celular. O axônio, também chamado de fibra nervosa quando possui um maior comprimento, tem por objetivo transmitir os sinais neurais para a célula nervosa seguinte ou para as células efetoras, como músculos e glândulas (ALBRECHT apud MARIEB et al., 2006). A unidade motora (vide Figura 2.2) consiste em um conjunto de fibras musculares inervadas pelo mesmo neurônio motor alfa.

A comunicação entre os neurônios motores e o músculo acontece através de uma junção neuromuscular com a placa motora, que é a região da membrana plasmática de uma fibra muscular, onde se dá o encontro entre o axônio e o músculo, permitindo desencadear a contração muscular.

Figura 2.2 – Representação de uma unidade motora.

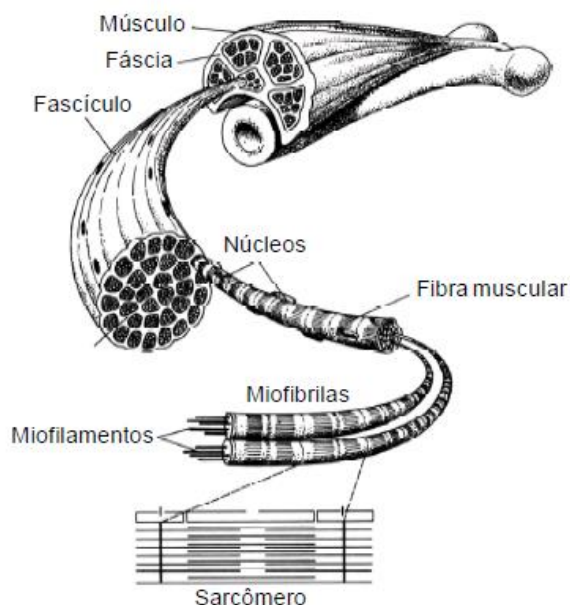


Fonte: Almeida (2012).

Os músculos esqueléticos (Vide Figura 2.3) são ligados aos ossos do esqueleto, possibilitando movimento. Eles são envoltos por um tecido conjuntivo, a fáscia. Esses músculos possuem estruturas chamadas de fascículos que, por sua vez, são conjuntos de fibras musculares. Estas possuem miofibrilas, compostas por miofilamentos e por sarcômeros, que formam a unidade contrátil muscular. O número de fibras musculares controladas por um único neurônio motor varia bastante, de 50 a 1000, e o número de unidades motoras presentes em um músculo, por sua vez, varia entre 10 a 3000 (LOEB; GHEZ, 2000). Essas características dependem do grupo muscular em questão (ALMEIDA, 2012).

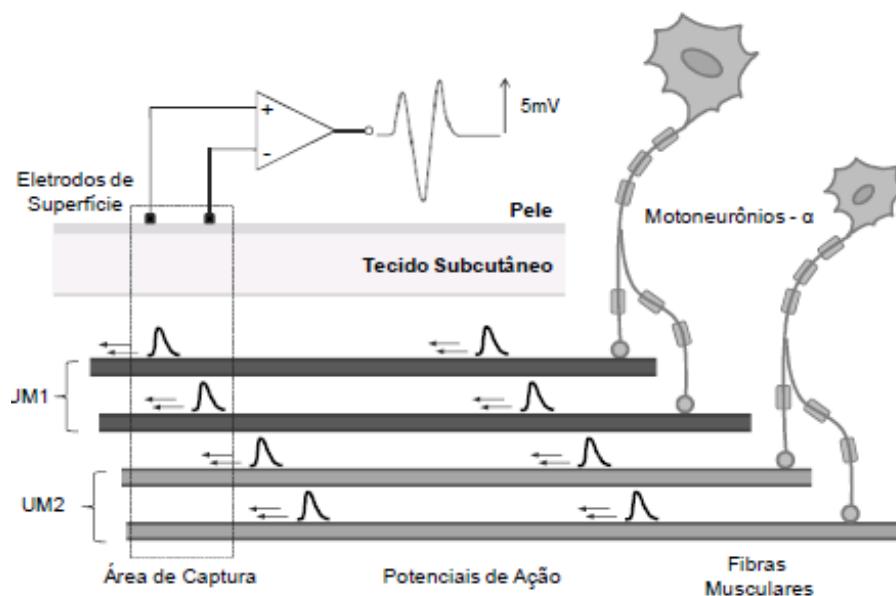
As características do sistema neuromuscular podem ser encontradas através da análise de PAs associados ao recrutamento de UMs, formando os Potenciais de Ação de uma Unidade Motora (*Motor Unit Action Potential – MUAP*), que podem ser detectados de forma invasiva (com eletrodos agulha) ou na superfície da pele (com eletrodos de superfície). O processo de detecção de sinais EMG envolve a transdução de correntes iônicas, presentes nos sistemas biológicos, normalmente, em corrente elétrica por eletrodos (vide Figura 2.4) (ALMEIDA, 2012 apud POZZO et al., 2004).

Figura 2.3 – Estrutura do músculo esquelético.



Fonte: Almeida (2012).

Figura 2.4 – Representação de duas UMs propagando MUAPs e a captura do sinal sEMG.



Fonte: Almeida (2012) apud Garcia et al (2005).

A depender do tipo de captura, o efeito volume condutor pode apresentar um efeito considerável ou desprezível no sinal EMG.

Para casos não invasivos, ou seja, de superfície, o sistema de detecção é localizado muito longe das fontes, e o sinal propagado até os eletrodos sofre muita influência dos tecidos presentes entre as fontes e os eletrodos, afetando o sinal

consideravelmente. O efeito de filtro passa-baixa dos tecidos limita as componentes de frequência do sinal sEMG em até 500Hz (ALMEIDA, 2012).

2.2.2 Tipos de Eletrodos

Geralmente são confeccionados com Prata e cobertos com Cloreto de Prata (Ag-AgCl), por ser uma liga metálica não polarizável, evitando o aparecimento de offsets na medição.

Os tecidos localizados entre as fontes e os eletrodos de captura têm um comportamento de filtro passa-baixa, e quanto mais longe o sistema de aquisição for posicionado da fonte, maior será o ruído e maior a influência desse filtro no sinal capturado. Esse comportamento é conhecido como efeito volume condutor, e as características desse efeito afetam diretamente o sinal detectado (ALMEIDA, 2012 apud POZZO et al., 2004). A depender de como seja o tipo de captura, o efeito volume condutor pode apresentar um efeito considerável ou desprezível no sinal EMG.

2.2.2.1 Eletrodos Intramusculares


Os Eletrodos intramusculares são compostos de finos fios metálicos ou agulhas, que permitem a captação de sinais bastante precisos (altas amplitudes, espectro de frequência mais largo e maior relação Sinal-Ruído), em regiões bem definidas, evitando interferências de outros músculos, porém, causam grande desconforto ao usuário, não se conseguindo uma grande repetibilidade dos experimentos (ORTOLAN, 2002).

Os eletrodos-agulha (Figura 2.5) são utilizados quando é necessário realizar o reposicionamento do eletrodo durante a análise, no caso de análises de vários pontos diferentes do músculo. Porém, este tipo possui a desvantagem de poder se deslocar durante uma contração. Já os eletrodos de fio foram desenvolvidos justamente para sanar essa dificuldade, pois possuem um gancho que os entrelaça às fibras musculares uma vez posicionados, evitando deslocamento durante a contração muscular. Todavia, estes não permitem reposicionamento (DE LUCA, 2006).

No caso de aquisição de sinais de forma invasivas, a área de captura é localizada muito próxima das fontes, e o sinal direcionado até os eletrodos sofre pouca influência dos tecidos presentes entre as fontes e os eletrodos, geralmente, o sinal capturado apresenta frequências até 5kHz.

Em geral, eletrodos invasivos são utilizados para análise de características de MUAPs, propriedade de controle das UMs e estudos cinesiológicos e neurofisiológicos em músculos mais profundos (QUEVEDO, 1993).

Figura 2.5 – Eletrodo invasivo: tipo agulha.



Fonte: Kendel (2018).

2.2.2.2 Eletrodos de superfície

Os eletrodos de superfície (Figura 2.6) utilizam técnicas não invasivas que capturam sinais mioelétricos na superfície da pele, sem a necessidade da inserção de eletrodos de agulhas ou fios dentro do músculo (ALMEIDA, 2012).


São constituídos por pequenas placas que ficam grudadas à pele do usuário, portanto, são facilmente aplicáveis. Apesar disso, possuem limitações quanto à precisão de seus sinais, que ficam em uma faixa entre 0 e 500 Hz em amplitudes máximas de 10 mV, sendo muito recomendada a utilização de pasta ou gel condutor, a fim de diminuir a impedância de contato eletrodo-pele. Deve-se ainda ressaltar que a utilização de eletrodos de superfície permite apenas a captação de sinais mioelétricos próximos à superfície da pele e são mais suscetíveis às interferências de outros músculos, fazendo do seu correto posicionamento característica importante do sinal eletromiográfico de superfície - sEMG (ORTOLAN, 2002). Devido ao fato de aspectos como a espessura e condutividade das camadas subcutâneas, da profundidade da fonte e da geometria dos eletrodos influenciarem no processo, tem-se como resultado um sinal com aparência de ruído aleatório, tornando difícil interpretação do mesmo (ALMEIDA, 2012).

Para estes eletrodos, o sistema de detecção é localizado muito longe das fontes, e o sinal propagado até os eletrodos sofre muita influência dos tecidos presentes entre as fontes e os eletrodos, afetando o sinal consideravelmente. O efeito de filtro passa-

baixa dos tecidos limita as componentes de frequência do sinal sEMG em até 500Hz (ALMEIDA, 2012).

Os eletrodos de superfície ainda podem ser classificados considerando os materiais e as tecnologias adotadas para sua fabricação. Podem-se distinguir entre eles, os considerados secos e os úmidos.

Figura 2.6 – Eletrodo de superfície.



Fonte: Kandel (2018).

Eletrodos secos: destacam-se os eletrodos de pinos ou barras feitas de metais nobres (por exemplo, ouro, platina ou prata), carbono, eletrodos de cloreto de prata.

Eletrodos úmidos: consistem em todos os eletrodos que incluem uma camada de gel condutivo, hidrogel ou esponja saturada com uma solução eletrolítica. Esses eletrodos costumam ser autoadesivos, portanto, podem ser facilmente aplicados e usados para análise de sinais EMG dinâmicos (MERLETTI, 2009).

Eletrodos Ativos: quando possuem um primeiro banco de amplificação e/ou filtragem analógica muito próxima do contato eletrodo-pele, tendo como principal vantagem o aumento da relação sinal-ruído (MERLETTI, 2009; ALMEIDA, 2012).

Estes eletrodos apresentam um amplificador de alta impedância de entrada integrado ao encapsulamento do eletrodo, pois o torna menos sensível à impedância da interface eletrodo-pele. Logo, foram desenvolvidos com o objetivo de eliminar o preparo da pele e a aplicação de gel condutor. Porém, apresentam um maior nível de ruído intrínseco e a qualidade dos sinais EMG capturados é menor devido a transpiração e oscilações naturais encontradas na superfície da pele (DE LUCA, 2006).

Eletrodos Semi-ativos: quando o primeiro banco de amplificação e/ou filtragem se encontra no meio do cabo que leva o sinal do eletrodo em si à parte eletrônica do sistema, mais próximo do contato eletrodo-pele (MERLETTI, 2009).


Passivos: Eletrodos passivos possuem uma superfície de detecção condutiva, normalmente de metal, com o qual correntes através da pele são captadas pela interface eletrodo-pele. Possui a parte eletrônica do sistema localizada longe do contato eletrodo-pele (MERLETTI, 2009; ALMEIDA, 2012).

A forma mais simples de eletrodos passivos consiste em discos de prata que aderem à pele, melhora-se significativamente o contato elétrico com a aplicação de gel condutor, contendo íons de cloreto, entre o eletrodo e a pele. A corrente iônica que surge no gel é transformada em corrente elétrica no eletrodo. Para melhores resultados, pode-se remover a camada superficial de pele através de leve abrasão. Para garantir um bom contato entre o eletrodo e a pele, pode-se fixar os eletrodos na pele com fitas adesivas. Muitos deles já vêm com uma região adesivada para facilitar o posicionamento e fixação (DE LUCA, 2006).

Classificação quanto à configuração utilizada:

Monopolar - na qual são utilizados apenas dois eletrodos, um para o sinal e um para a referência, conforme a Figura 2.7, geralmente localizado longe do eletrodo de sinal, em lugares com pouca atividade bioelétrica.

Figura 2.7 – Configuração do eletrodo em modo monopolar.



Fonte: Almeida (2012).

A principal vantagem dessa configuração é a montagem simples e rápida, que resulta na captura de todos os sinais elétricos presentes na área de detecção do

eletrodo, incluindo sinais elétricos e ruídos indesejados provenientes de outras fontes além do músculo em análise (Equação 2.1) (ALMEIDA, 2012).

$$EMG\ sig = G \cdot (m + n) \quad 2.1$$


onde $EMG\ sig$ representa o sinal EMG capturado, G é o ganho do amplificador, m é o sinal mioelétrico de interesse e n representa sinais elétricos e ruídos indesejados.

Bipolar - onde são utilizados três eletrodos, dois para o sinal, geralmente em configuração diferencial, e um para a referência, conforme a Figura 2.8. Esta configuração utiliza duas superfícies para detectar dois potenciais do músculo em análise, cada qual em relação a um eletrodo de referência em comum (DE LUCA, 2006). Os dois sinais capturados passam por um amplificador diferencial que amplifica a diferença entre os dois sinais, eliminando qualquer componente de modo comum presente nos dois sinais (exemplo, sinais de fontes e equipamentos elétricos), conforme Equação 2.2.

$$EMG\ sig = G \cdot [(m_1 + n) - (m_2 + n)] = G \cdot (m_1 - m_2) \quad 2.2$$

onde $EMG\ sig$ representa o sinal EMG capturado, G é o ganho do amplificador, m_1 é o sinal mioelétrico capturado pelo primeiro eletrodo, m_2 é o sinal mioelétrico capturado pelo segundo eletrodo e n é o ruído comum capturado pelos dois eletrodos.

Figura 2.8 – configuração do eletrodo em modo bipolar.



Fonte: Almeida (2012) apud De Luca (2006).


2.2.3 Fatores que afetam o sinal e a intensidade do EMG Produzido por um músculo

O sinal EMG é o resultado de muitos fatores fisiológicos, anatômicos e técnicos. Os efeitos de alguns desses fatores podem ser gerenciados por métodos de detecção adequados, mas outros não são facilmente regulados com a tecnologia atual. O estado atual do conhecimento não permite considerar quantitativamente a causa e o efeito de todos os processos e fenômenos que influenciam o sinal EMG. Mesmo que as influências pudessem ser completamente caracterizadas, a interpretação analítica seria complicada pela anisotropia e falta de homogeneidade dos tecidos entre as membranas musculares e o eletrodo de detecção. A análise seria ainda mais confusa pela singularidade das estruturas microanatômicas de cada local de detecção.

Os fatores causais têm um efeito básico ou elementar no sinal. Estes são divididos em dois grupos: extrínsecos e intrínsecos. Os fatores causadores extrínsecos são aqueles associados à estrutura do eletrodo e sua colocação na superfície da pele acima do músculo (vide Figura 2.9). Eles incluem o seguinte:

- A área e a geometria das superfícies de detecção de eletrodos, que determinam o número de unidades motoras ativas detectadas em virtude do número de fibras musculares em sua vizinhança;
- A distância entre as superfícies de detecção do eletrodo, que determina a largura de banda da configuração diferencial do eletrodo.
- A localização do eletrodo em relação aos pontos motores no músculo, que influenciam as características de amplitude e frequência do sinal detectado.
- A localização do eletrodo na superfície do músculo em relação à borda lateral do músculo, que determina a quantidade de *crosstalk*, - interferência indesejada que um canal de transmissão causa em outro - que pode ser detectada pelo eletrodo.
- A orientação das superfícies de detecção em relação às fibras musculares, que afeta o valor da velocidade de condução medida dos potenciais de ação e, conseqüentemente, o conteúdo de amplitude e frequência do sinal.

Figura 2.9 – Amplitude e frequência do sinal EMG em relação ao posicionamento de eletrodos.



Fonte: Almeida (2012) apud De Luca (1997).

Os fatores causais intrínsecos se referem às características fisiológicas, anatômicas e bioquímicas do músculo. Eles incluem:

- O número de unidades motoras ativas em qualquer momento específico da contração, o que contribui para a amplitude do sinal detectado;
- Composição do tipo de fibra do músculo, que determina a mudança no pH do fluido intersticial do músculo durante uma contração;
- Fluxo sanguíneo no músculo, que determina a taxa na qual os metabólitos são removidos durante a contração;
- Diâmetro da fibra, que influencia a amplitude e a velocidade de condução dos PAs que constituem o sinal;
- Profundidade e localização das fibras ativas dentro do músculo em relação às superfícies de detecção dos eletrodos; essa relação determina a filtragem espacial e, conseqüentemente, as características de amplitude e frequência do sinal detectado;
- A quantidade de tecido entre a superfície do músculo e o eletrodo, que afeta a filtragem espacial do sinal.

2.2.4 Impedância e ruído do sinal EMG

Por possuir uma natureza estocástica o sinal EMG pode ser representado por uma função de distribuição Gaussiana. Entre a faixa 0 e 500Hz encontra-se a maior parte da energia útil do sinal, com a energia dominante entre 50 a 150 Hz (DE LUCA, 2002).

Os principais parâmetros a serem observados em um sistema de captura de sinais EMG são (QUEVEDO, 1993):

- Ruído intrínseco do sistema: Faixa de ruído aceitável intrínseco ao sistema de captura deve ser entre $1\mu V_{rms}$ e $5\mu V_{rms}$ (SAMPAIO, 1998).
- Ganho: O sinal sEMG possui tensões de pico da ordem de $50\mu V$ a $5mV$ (Quevedo, 1993). O amplificador deve garantir uma boa amplificação, mantendo a melhor relação sinal-ruído possível (NAGEL, 2000).
- Razão de rejeição de modo comum (CMRR - *Common Mode Rejection Ratio*): Quanto maior o CMRR, melhor a capacidade do sistema em minimizar ruídos em modo comum. De Luca (2006) recomenda CMRR acima 85dB.
- Impedância de entrada em modo comum: auxilia no isolamento do sistema de captura do sistema medido. A impedância de um sistema biológico varia entre $1k\Omega$ e $10k\Omega$ (NAGEL, 2000). Desta forma, quanto maior a impedância de entrada do sistema de captura, menor a interferência dele no sistema medido. E conforme Nagel (2000) ela deve ser maior que $10^9\Omega$.
- Largura da banda do sinal: O sinal sEMG possui uma faixa de frequência de 20Hz a 500Hz (DE LUCA, 2006), com energia dominante entre 20Hz e 150Hz (KARLSSON et al, 2008). Logo, o sistema de captura deve limitar o sinal capturado para dentro da faixa de frequência entre, pelo menos, 20Hz a 500Hz.

Ao detectar e registrar o sinal EMG, há dois principais problemas que influenciam a fidelidade do sinal. O primeiro é a razão entre a energia no sinal EMG e a energia no sinal de ruído. A outra é a distorção do sinal, significando que a contribuição relativa de qualquer componente de frequência no sinal EMG não deve ser alterada (DE LUCA, 2002).

Devido ao fato de o valor da impedância depender do tempo, bem como de muitos parâmetros, como os materiais do eletrodo, a composição química do gel, o tamanho do eletrodo e a estrutura da superfície, e o tratamento da pele. Durante gravações de longa duração, a secagem do gel, alterações das propriedades da pele

e da interface eletrólito-pele podem causar variações significativas da impedância do eletrodo-pele. Em geral, um procedimento correto de medição da impedância do eletrodo-pele deve considerar toda a largura de banda do EMG (10–500Hz) e correntes na faixa de μA_{rms} a nA_{rms} , uma vez que a tensão do sinal EMG está na faixa de μV_{rms} a mV_{rms} e a impedância de entrada do amplificador do EMG está na faixa de centenas de $M\Omega$ (MERLETTI, 2009).

Outro ponto relevante é o nível de ruído do eletrodo. A interface metal-eletrólito é intrinsecamente ruidosa devido aos diferentes portadores de carga nas duas fases. Nas frequências acima de 100 Hz, o ruído do eletrodo de superfície é similar ao ruído térmico gerado pela resistência do eletrodo-pele, enquanto frequências menores que 100 Hz, o ruído da interface eletrodo-pele foi significativamente maior em relação ao ruído térmico (GONDRAN et al., 1996). As características espectrais do ruído eletrodo-pele mostraram um comportamento $1/f$ para frequências muito baixas ($f < 30$ Hz), enquanto que em frequências mais altas o ruído do amplificador do sinal EMG foi dominante (HUIGEN et al., 2002). Em geral, os eletrodos Ag-AgCl apresentam a menor interface de ruído e são recomendados para gravação dos sinais EMG (FRERIKS et al., 1997). Além disso, o nível do ruído eletrodo-pele depende significativamente do tratamento do estado da pele (HUIGEN et al., 2002; CLANCY et al., 2002) portanto, recomenda-se uma leve abrasão da pele para diminuir os valores de ruído e impedância.

O sinal eletromiográfico de superfície (EMGs) contém o sinal que se origina no músculo e vários componentes do ruído que são endêmicos e inevitáveis. Esses componentes de ruído contaminam o sinal EMG e podem levar a uma interpretação errônea do sinal. Este é especialmente o caso quando o sinal é obtido durante as contrações dinâmicas e quando se pretende fornecer informações sobre a fisiologia e anatomia dos músculos (DE LUCA, 2010). Ele também pode ser contaminado por diversos tipos de ruído que são causados por equipamentos e ambiente, radiação eletromagnética, movimentação, e a interação de diferentes tecidos. Às vezes, é difícil extrair características úteis dos músculos residuais de um amputado ou pessoa sem movimentação do braço (AHSAN et al., 2011). A normalização da amplitude do sinal é uma alternativa para remover a influência de muitas outras variáveis (DE LUCA, 1997).

Na biomecânica, três aplicações dominam o uso do sinal EMG de superfície:

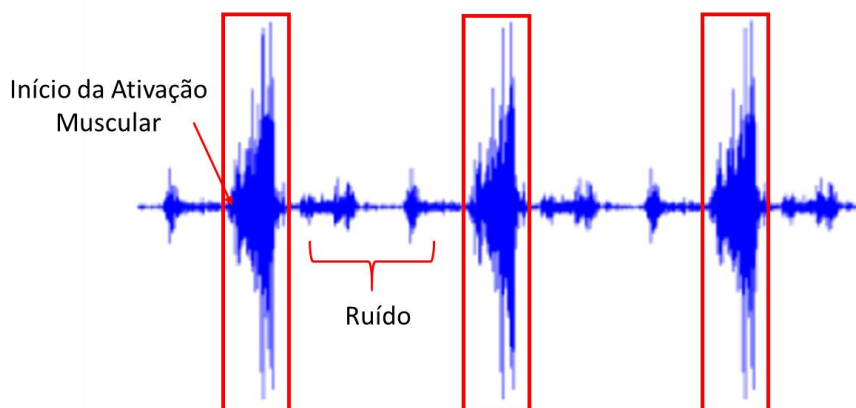
- Indicador do início da ativação muscular;
- Relação com a força produzida por um músculo e;
- O uso como um índice de processos de fadiga que ocorrem dentro de um músculo.

Como um indicador do início da atividade muscular, o sinal pode fornecer a sequência de tempo de um ou mais músculos executando uma tarefa, como durante a marcha ou na manutenção da postura ereta. Outra aplicação relevante do sinal de EMG é fornecer informações sobre a contribuição da força de músculos individuais, bem como grupos de músculos. O músculo individual fornece a maior atração, já que o momento muscular resultante que age em uma articulação durante uma tarefa específica é somente em casos excepcionalmente raros devido a um músculo.

A grande maioria dos casos de interesse tem como foco determinar de forma não invasiva a contribuição da força de músculos individuais, particularmente quando modelos biomecânicos são desenvolvidos para descrever o funcionamento de um segmento do sistema músculo-esquelético. O uso do sinal EMG para fornecer um índice de fadiga tem um apelo considerável porque foi demonstrado que o sinal exibe mudanças dependentes do tempo antes de qualquer modificação de força, tendo, portanto, o potencial de prever o início da fadiga contrátil (DE LUCA, 1997), podendo auxiliar os profissionais em reabilitação a avaliar o estado de avanço do paciente, o tempo de fadiga, dentre outros fatores relevantes referentes a uma evolução clínica.

Na Figura 2.10 pode-se visualizar um exemplo do sinal EMG referente a uma contração isométrica do tríceps, no qual este sinal foi amplificado 4400 vezes e adquirido a uma frequência de amostragem de 5kHz, segundo o autor (ANDRADE, 2000). Nota-se três janelas de execução do movimento, onde se inicia a ativação muscular e a representação do ruído.

Figura 2.10 – Exemplo Sinal eletromiográfico proveniente de uma contração isométrica do tríceps.



Fonte: Andrade (2000). Adaptado pela autora.

2.2.5 Sensor Myo®

A braçadeira de controle de gestos - Myo® - é uma tecnologia “vestível” sem fio, projetada pela *Thalmic Labs* em 2014, que usa a técnica de eletromiografia, possui oito sensores Eletromiográficos de classe médica e eixos inerciais: giroscópio, acelerômetro e magnetômetro, contempla três eixos (x, y, z), e formam a unidade de medida inercial (IMU). A braçadeira de gesto Myo® contém duas baterias em locais diferentes; cada bateria tem uma capacidade de 260 mAh e uma faixa de tensão operacional de 1,7 a 3,3 volts. A frequência de amostragem da braçadeira de controle de gestos Myo® é de 200 Hz. É usado para fins médicos, aplicações de sistemas de automação e para controlar o braço robótico. Além disso, este produto é suportado pelo *kit* de desenvolvimento de *software* (SDK) que permite a comunicação entre a braçadeira de gesto Myo® e outras aplicações, como o MATLAB do MathWorks (ABDUO; GALSTER, 2015).

Conforme Prindle (2015) e Hassan (2016), o sensor Myo® se trata de uma braçadeira que utiliza a técnica conhecida como eletromiografia (EMG). É usada como equipamento de aquisição de dados para registrar o conjunto de treinamento e teste de sinais sEMG. sendo assim, é capaz de captar sinais elétricos dos músculos do antebraço e mapeá-los para gestos feitos com as mãos, com o intuito de controlar outros dispositivos com esses gestos. Possui a vantagem de dispensar o uso de câmeras, que dependem de boa luminosidade, distância e caminho sem obstruções, como a maioria dos sistemas de controle de gestos.

Os eletrodos na braçadeira Myo® estão posicionados de forma circular e os principais músculos que cobrem a região são os músculos superficiais responsáveis por extensões (região posterior do antebraço) e os músculos flexores (região anterior do antebraço). Estes são os músculos que movem o pulso, os dedos (indicador, médio, anelar e mínimo) (ARIEF et al., 2015).

Para caracterizar adequadamente a atividade muscular do antebraço, este sensor é dividido em oito blocos diferentes (Figura 2.11), cada um contendo um sensor EMG (cada sensor é considerado um canal) de classe médica, que são inoxidáveis. Tem vantagens sobre outros sensores EMG de superfície porque não são necessários cabos, as mãos podem ser movidas livremente, é fácil de usar, relativamente barato, pequeno em tamanho e leve, pesando apenas 93 g e não se faz necessário o uso do gel eletrolítico (HASSAN, 2016).

A braçadeira de controle de gestos Myo® usa eletrodos de sEMG sem fio (sensores) que circundam o antebraço e detectam os sinais elétricos das atividades musculares. É um produto comercialmente pronto, adequado para gravar sinais de EMGs e dados espaciais relacionados à tendência e ao movimento do antebraço do usuário.

Figura 2.11 – Braçadeira Myo® e a ordem dos sensores.



Fonte: Myo® (2016).

No entanto, como o potencial elétrico do músculo é pequeno, a tensão dos sinais de sEMG é muito pequena, em torno de 0-2 mV. A braçadeira de gesto Myo® amplifica os sinais sEMG para que possam ser facilmente manipulados, visto que os sinais são sensíveis a outras fontes de ruído elétrico (ABDUO; GALSTER, 2015). Conforme Arief et al. (2015) os dados EMG de oito canais variam de -127 a 127 em unidades ADC. Não sendo necessária a conversão em tensão devido ao fato das unidades EMG reais em tensão serem extremamente pequenas, na faixa de microvolts.

Normalmente, os sinais sEMG coletados contêm muitos tipos de ruídos devido ao próprio ambiente, artefato de movimento, ruído inerente aos equipamentos eletrônicos e instabilidade inerente ao sinal. O ruído ambiente é originado devido à radiação de dispositivos eletromagnéticos, enquanto o ruído de artefato de movimento é causado pela interface entre o eletrodo e a pele. A instabilidade inerente do sinal ocorre devido aos efeitos dos sinais de sEMG causados pela taxa de disparo das unidades motoras dos músculos. Ao usar a braçadeira Myo®, devido ao processamento existente nela e ao tipo de eletrodo, a taxa de ruído nos sinais sEMG é considerada baixa, possuindo pouca influência nos dados. Esse recurso é considerado mais uma vantagem desta braçadeira (HASSAN, 2016).

Além do mais, possui um giroscópio – que realiza a medição da velocidade angular - um acelerômetro – que mede a aceleração linear, assim como a da gravidade – e um magnetômetro para detectar movimentos em qualquer direção, tendo três eixos cada. Essa atividade muscular obtida é manipulada por um processador ARM Cortex M4, que se comunica com seus dispositivos via *Bluetooth*. Segundo o fabricante – *ThalmicLabs*TM – a bateria interna de íons Lítio é suficiente para durar um dia inteiro de uso contínuo (PRINDLE, 2015). O Myo® possui boa resposta aos estímulos e possui compatibilidade com vários sistemas e plataformas, incluindo Windows e Mac, Android e iOS, possui também bibliotecas para uso com diversos dispositivos, o que facilita e expande o leque de possíveis aplicações.

Possui dois LEDs, cada um indica uma situação específica. O LED de status indica que a braçadeira Myo® está conectada a um computador via *Bluetooth* e aparece em cor azul. Esta cor muda para laranja quando a braçadeira Myo® é carregada. O LED da logo indica uma comunicação estabelecida entre a braçadeira Myo® e outro aplicativo, por exemplo, o MATLAB do *MathWorks*. Se o LED piscar, significa que não há conexão estabelecida.

Para começar, é necessário realizar a instalação do pacote de conexão Myo® para garantir a conexão entre a braçadeira de gesto Myo® e um computador via *Bluetooth*. Os pacotes TDM64-GCC-4.9.2, MinGW-w64-4.9.2 e Myo-SDK-win-0.9.0 são instalados para estabelecer a conexão entre a braçadeira de gesto Myo® e o MATLAB R2017. Depois de concluir todas as instalações de pacotes necessárias, a sincronização entre a braçadeira Myo® e o MATLAB R2017 é uma etapa necessária antes de gravar os sinais sEMG (HASSAN, 2016).

O sistema funciona em dois modos: *offline* e modo *online* (tempo real). O primeiro é desenvolvido para calcular a precisão do sistema e melhorar o desempenho do sistema, enquanto o segundo é usado para movimentação de dispositivos em tempo real. Estes dois modos podem ser implementados através do programa MATLAB R2017. Neste trabalho foi utilizado o modo *offline* para posterior tratamento dos dados brutos, em virtude da quantidade de testes e de voluntários na realização dos mesmos.

A braçadeira Myo® foi feita para funcionar melhor na parte mais larga do antebraço. Ao contrário de outros sensores EMG, a braçadeira Myo® não exige que o usuário raspe a área em torno da qual a braçadeira será usada. Isso permite procedimentos de configuração mais fáceis em ambientes experimentais ou do mundo real (ABDUO; GALSTER, 2015).

Este sensor possui, através do software fornecido pelo fabricante, o reconhecimento, através de uma breve calibração, de cinco gestos diferentes (mão fechada – *fist*, dedos espalhados – *fingers spread*, mão para dentro – *wave in*, mão para fora – *wave out* e duplo toque - *double tap* conforme a Figura 2.12.

Figura 2.12 – Movimentos de ‘Fist’, ‘Fingers Spread’, ‘Wave In’, ‘Wave Out’ e ‘Double Tap’ respectivamente.



Fonte: Myo® (2016).

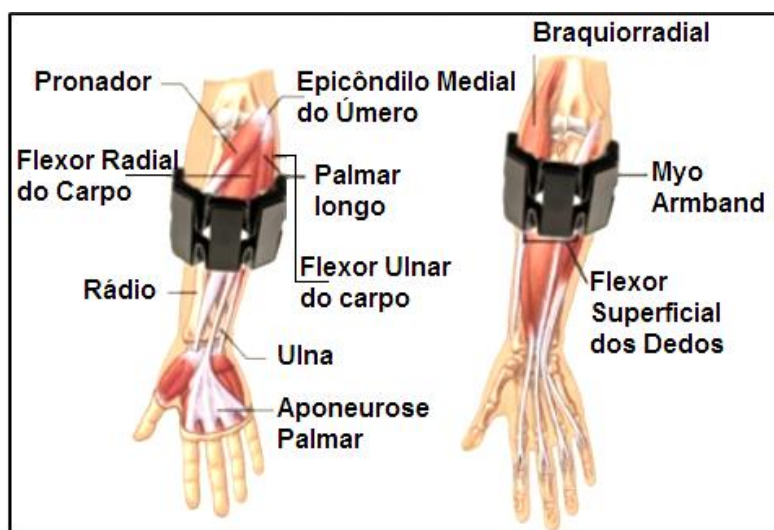
O antebraço é formado pelo grupo anterior (flexores do punho e dos dedos e pronadores) e o grupo posterior (extensores do punho e dos dedos e supinadores) (GANIEV,2016). A Figura 2.13 mostra alguns dos principais músculos (região mais escura da ilustração) da região anterior do antebraço situados onde a braçadeira Myo® é utilizada. O músculo palmar longo, por exemplo, é responsável por fletir o pulso e esticar a aponeurose palmar (AGUR; DALLEY, 2006).

De acordo com a sequência de eletrodos ilustrada na Figura 2.11, cada eletrodo é responsável pela captação de determinados músculos. Baseando-se numa utilização correta a correlação é representada da seguinte forma (vide Figura 2.14):

- Eletrodo 1: Palmar Longo;
- Eletrodo 2: Flexor Ulnar do Carpo;
- Eletrodo 3: Extensor Ulnar do Carpo/ Extensor do dedo Mínimo;
- Eletrodo 4: Extensores dos Dedos;
- Eletrodo 5: Extensor Radial Curto e Longo do Carpo;
- Eletrodo 6: Braquiorradial;
- Eletrodo 7: Pronador Redondo;
- Eletrodo 8: Flexor Radial do Carpo.

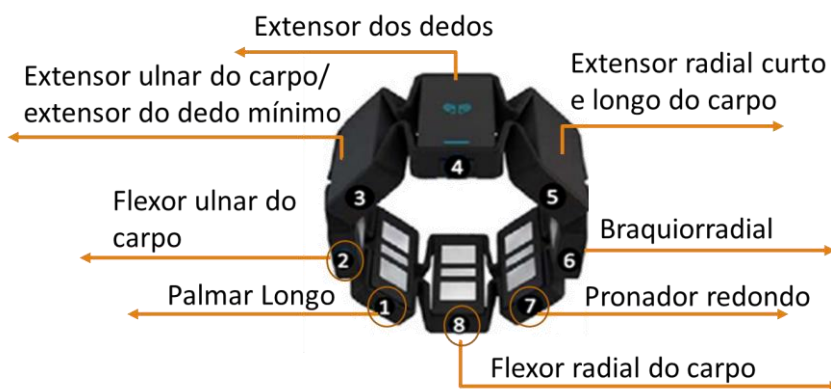
Vale ressaltar que os Eletrodos 1, 2, 7 e 8 (eletrodos circutados na Figura 2.14) atingem o músculo flexor superficial dos dedos. E os Eletrodos 3, 4 e 5 representam os movimentos de extensão na região posterior do antebraço.

Figura 2.13 – Músculos do antebraço.



Fonte: Ganiev (2016) – Adaptado pela autora.

Figura 2.14 – correlação entre os eletrodos da braçadeira e os músculos superficiais.



Fonte: Autoria própria.

Capítulo 3

3. REDES NEURAIS ARTIFICIAIS - RNA

As redes neurais são interessantes para a solução de diversos tipos de problemas como: reconhecimento de padrões (visão computacional, reconhecimento de voz, etc.), processamento de sinais, diagnóstico de falhas, identificação e controle de processos, dentre outros, devido às seguintes características (BITTENCOURT, 2016):


- Capacidade de aprender através de exemplos e de generalizar este aprendizado;
- Bom desempenho em tarefas mal definidas, onde falta conhecimento explícito sobre como o fenômeno funciona;
- Não requer conhecimentos a respeito de eventuais modelos matemáticos dos domínios de aplicações;
- Apresenta elevada imunidade ao ruído, ou seja, a rede não entra em colapso com informações falsas.

3.1 O Modelo de McCulloch e Pitts

A estrutura do neurônio artificial proposto é baseada no neurônio biológico conforme a Figura 3.1, na qual é possível observar, de maneira simplista, que ele é formado por:

- Corpo celular ou soma: contém o núcleo da célula;
- Dendritos: receptores de impulsos elétricos;
- Axônio: transmissores de impulsos elétricos.

Figura 3.1 – Neurônio Biológico.




Fonte: Bittencourt (2016).

A propagação de um impulso elétrico ao longo de um dendrito ou de um axônio acontece através da alteração da concentração dos íons K^- e Na^+ em ambos os lados da membrana. Já as interligações entre os neurônios são efetuadas através de sinapses, que é o ponto de contato entre os transmissores e receptores controlados por impulsos elétricos e por reações químicas dos neurotransmissores.

O primeiro modelo matemático para uma RNA, proposto por McCulloch e Pitts, foi realizado de forma simplista e se tratava de um dispositivo binário (Figura 3.2), sendo a saída um pulso ou não-pulso (ativo ou não), e as entradas tinham um ganho arbitrário, podendo ser excitatórias ou inibitórias. A saída era determinada pelo cálculo da soma ponderada das entradas com os respectivos pesos como fatores de ponderação, se o resultado atingisse um certo limiar, a saída do neurônio era ativa, caso contrário, não (ZAMBIASI, 2002).

Figura 3.2 – Neurônio de McCulloch.



Fonte: Zambiasi (2002).

Assim como o neurônio biológico, o neurônio artificial possui um ou mais sinais de entradas e apenas um sinal de saída. Estes sinais são processados e enviados à

saída, sendo que todas as informações de entrada devem chegar ao núcleo do neurônio artificial simultaneamente (ZAMBIASI, 2002).

A Figura 3.3 mostra a generalização do modelo de McCulloch e Pitts em forma de uma Equação do Neurônio Artificial. Neste modelo, X_i são as entradas, W_i são os pesos, estes são combinados usando uma *Função Soma* para produzir um estado de ativação do neurônio através da *Função de Ativação* ou *Limiar Lógico*. Uma vez satisfeito o limiar desta função, será produzida a saída do neurônio, que prosseguirá para a camada seguinte (BARRETO, 2002).


Segundo Zambiasi (2002), os pesos representam o grau de importância que determinada entrada possui em relação àquele neurônio. O valor deles é alterado em função da intensidade do sinal de entrada, mudando o seu valor representativo para a rede (processo de aprendizagem).

O sinal de saída do neurônio é o resultado do produto escalar das entrada pelos pesos:

$$\sum_{i=0}^n X_i W_i \quad (3.1)$$

após esta operação, os sinais de entrada passam a ser conhecidos como entradas ponderadas (ZAMBIASI, 2002).

Figura 3.3 – Representação do Neurônio Artificial.



Fonte: Autoria própria.


3.2 Arquitetura das Redes Neurais Artificiais

As RNA podem ter uma ou várias camadas. As redes que possuem apenas uma camada (Figura 3.4) são as que possuem um nó entre uma entrada e uma saída, sendo indicada para a solução de problemas linearmente separáveis. As redes multicamadas (Figura 3.5) possuem mais de uma camada entre as camadas de

entrada e saída que são chamadas de camadas intermediárias ou ocultas (ZAMBIASI, 2002).

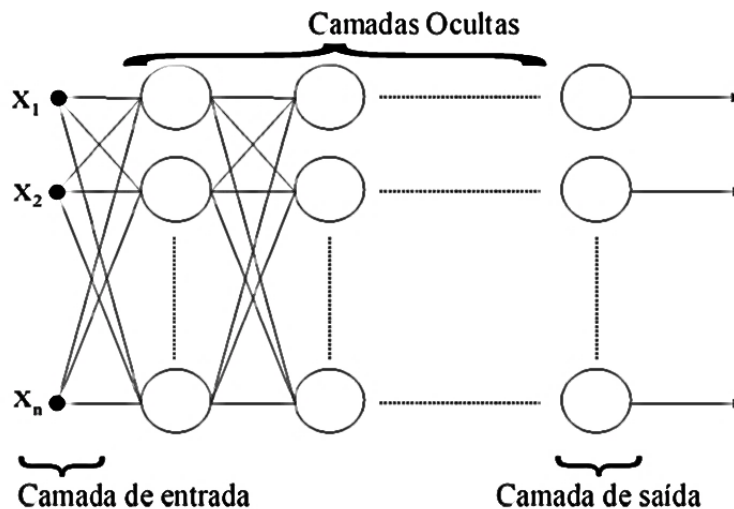
As camadas intermediárias são formadas por neurônios artificiais como qualquer outra camada, porém os sinais são passados para os outros neurônios obedecendo as funções de transferência que cada neurônio possui (ZAMBIASI, 2002 apud KASABOV, 1996).

Figura 3.4 – RNA de uma única camada.



Fonte: Zambiasi (2002).

Figura 3.5 – RNA multicamada.




Fonte: Zambiasi (2002).

Esses nós que compõem a RNA podem ter conexões do tipo:

- *Feedforward* ou acíclica (Figura 3.6): A saída de um neurônio na camada i não pode ser usada como entrada em nós das camadas inferiores (ZAMBIASI, 2002 apud CARVALHO; LUDEMIR, 1998). Essa é uma aplicação típica para o desenvolvimento de modelos não-lineares

que também são usados para o reconhecimento e classificação de padrões.


Figura 3.6 – RNA *Feedforward*.



Fonte: Zambiasi (2002).

- *Feedback* ou cíclica (Figura 3.7): A saída de um neurônio na camada i pode ser usada como entrada em camadas de índices inferiores. Este tipo de rede associa um padrão de entrada com ele próprio, e são aplicados para a recuperação ou regeneração de um padrão de entrada (ZAMBIASI, 2002 apud CARVALHO; LUDEMIR, 1998).

Figura 3.7 – RNA *Feedback*.




Fonte: Zambiasi (2002).

3.2.1 Rede Multilayer Perceptron – MLP

Este tipo de rede foi idealizado para resolver problemas complexos, que não podem ser simplesmente solucionados com um modelo de neurônio básico. Para que uma combinação da saída de alguns *perceptrons* (tipo de RNA mais simples para classificação de padrões que possui apenas um neurônio) tenham capacidade de aprendizado são necessárias mais conexões, que é validada numa rede de *perceptrons* dispostos em camadas (SOUZA, 2011). Um exemplo desta rede pode ser visto na Figura 3.8.

Figura 3.8 – Exemplo de rede MLP.



Fonte: Souza (2011).

3.3 Algoritmo de Treinamento

3.3.1 Resilient Backpropagation

O algoritmo *Backpropagation* é bastante utilizado para o treinamento de redes neurais. Ele é constituído por duas etapas: Propagação e Retropropagação de um conjunto de sinais através da rede. A primeira, consiste em realizar a aquisição de dados e os propagar por toda a rede, produzindo uma saída que é comparada com a saída desejada e é calculado um valor de erro. Com esse valor de erro calculado, inicia-se o processo de retropropagação, onde esse erro é propagado de volta para a rede e usado para ajustar os pesos, objetivando minimizar a cada nova tentativa esse erro e fazendo com que o resultado se aproxime do desejado (SOUZA, 2011).

O algoritmo *Resilient Backpropagation* – RBP ou Rprop foi introduzido por Riedmiller & Braun (1993) (AL-SULTANI, 2012). Sendo um método amplamente utilizado para reconhecer os padrões complexos, trata-se de uma modificação ao método utilizado no algoritmo tradicional *Backpropagation* (KORDOS, 2005). Além de ser eminentemente adequado para aplicações em que o gradiente é estimado numericamente ou o erro é ruidoso (ANASTASIADIS, 2005).

O algoritmo RBP tem por característica acelerar a taxa de aprendizado em relação ao *Backpropagation* padrão (AVAN et al., 2017). Além disso, segundo Anastasiadis (2005) o princípio básico de RBP é eliminar a influência prejudicial do tamanho do gradiente (derivada parcial) na etapa de peso. Como consequência, apenas o sinal da derivada é considerado para indicar a direção da atualização de peso.

No algoritmo *Backpropagation* convencional o gradiente de erro geralmente causa uma alteração grande na matriz de pesos. Já no *Resilient Backpropagation*, analisa o sinal do gradiente e descarta grandes magnitudes. Ou seja, só importa se ele é positivo, negativo ou próximo de zero, conforme apresentado na Equação 3.2. Se a magnitude for pequena, nenhuma matriz de peso ou limiar será ajustado. Se ela for positiva, o peso será aumentado por uma constante e, se for negativa, o peso será diminuído (STEVENS; LOVRIC, 2011).

$$\Delta w_{ij}(t) = \begin{cases} -\Delta_{ij}(t), & \text{se } \frac{\partial E(t)}{\partial w_{ij}} > 0, \\ +\Delta_{ij}(t), & \text{se } \frac{\partial E(t)}{\partial w_{ij}} < 0, \\ 0, & \text{caso contrário} \end{cases} \quad (3.2)$$

onde $\frac{\partial E(t)}{\partial w_{ij}}$ denota o verdadeiro gradiente, sendo a derivada do erro com relação ao peso, que é somado a todos os padrões do conjunto de treinamento. A segunda etapa do aprendizado RBP é determinar os novos valores de atualização (ANASTASIADIS, 2005).

$$\Delta w_{ij}(t) = \begin{cases} \eta^+ \cdot \Delta_{ij}(t-1), & \text{se } \frac{\partial E(t-1)}{\partial w_{ij}} \cdot \frac{\partial E(t)}{\partial w_{ij}} > 0, \\ \eta^- \cdot \Delta_{ij}(t-1), & \text{se } \frac{\partial E(t-1)}{\partial w_{ij}} \cdot \frac{\partial E(t)}{\partial w_{ij}} < 0, \\ \Delta_{ij}(t-1), & \text{caso contrário,} \end{cases} \quad (3.3)$$

quando $0 < \eta^- < 1 < \eta^+$. Onde η^+ é o fator de aumento e η^- é o fator de diminuição.

Segundo Anastasiadis (2005) sempre que a derivada parcial do peso representada por $w_{ij}(t)$ tiver seu sinal alterado, indicando que a última atualização foi muito grande e o algoritmo saltou sobre o mínimo local, o valor de atualização $\Delta_{ij}(t)$ é diminuído pelo fator η^- . Caso a derivada mantenha seu sinal, o valor de atualização será aumentado ligeiramente a fim de acelerar a convergência em regiões rasas.

Além disso, segundo (ANASTASIADIS, 2005) no caso de mudança no sinal, não deve haver adaptação na etapa de aprendizagem subsequente. Na prática, isso pode ser alcançado definindo $\frac{\partial E(t)}{\partial w_{ij}} = 0$ na regra de adaptação. Esta estratégia ajuda a acelerar a convergência quando a derivada é negativa, mas pode ser ineficiente quando as duas derivadas são positivas, como neste caso as atualizações de pesos podem levar a trajetória para longe do mínimo local ou em regiões com valores de função de erro mais altos. Na tentativa de minimizar essas situações, a RBP emprega um parâmetro heurístico Δ_{\max} , que restringe o tamanho da etapa de atualização.

3.3.2 Levenberg-Marquardt

O algoritmo de *Levenberg-Marquardt* é considerado o mais efetivo para treinamento de Redes Neurais Artificiais, porém de grande complexidade computacional e a dificuldade de calcular a região de confiança (DIAS, ANTUNES, *et al.*, 2004).

Este algoritmo foi projetado para abordar a velocidade de treinamento de segunda ordem sem precisar calcular a matriz hessiana. Quando a função de desempenho tem a forma de uma soma de quadrados (típico em redes *feedforward*), a matriz hessiana pode ser admitida como (KISI; UNCUOLU, 2005):

$$H = J^T J \quad (3.4)$$

cujo gradiente pode ser calculado como:

$$g = J^T e \quad (3.5)$$

onde J é a matriz jacobiana, que contém as primeiras derivadas dos erros de rede em relação aos pesos e *bias*, e e é um vetor de erros de rede. A matriz Jacobiana pode ser calculada através de uma técnica padrão de propagação reversa que é muito menos complexa do que a matriz Hessiana.

O algoritmo de *Levenberg-Marquardt* usa essa aproximação para a matriz hessiana na equação de atualização dos pesos semelhante ao método de Gauss-Newton (HAGAN; MENHAJ, 1994):

$$w_{k+1} = w_k - [J^T J + \mu I]^{-1} J^T e \quad (3.6)$$

Quando o escalar μ for igual a zero, a equação pode ser considerada como sendo o método de Gauss-Newton, usando a matriz hessiana aproximada. Quando μ for maior que zero, torna-se um método gradiente descendente com um ganho baixo. O método de Newton é considerado o mais rápido e o mais preciso perto de um erro mínimo, então é interessante fazer como que o μ chegue a zero. O valor de μ é diminuído após cada etapa bem sucedida (redução na função de desempenho) e é aumentado apenas quando um passo experimental aumenta a função de desempenho. Desta forma, a função de desempenho será sempre reduzida a cada iteração do algoritmo. A técnica de otimização de *Levenberg-Marquardt* é mais complexa que as técnicas convencionais de gradiente descendente (KISI; UNCUOLU, 2005).

3.3 Processo de Reconhecimento de Padrões

O processo de reconhecimento de padrões pode ser definido como o “processo pelo qual um padrão/sinal recebido é atribuído a uma classe dentre um número predeterminado de classes (categorias)” (HAYKIN, 2001).

Este processo pode ser dividido em duas etapas: extração de características e classificação. O sinal mioelétrico é redundante e ruidoso, ou seja, existe uma parte que não contribui com informação útil. A fase de extração de características tem por objetivo selecionar um conjunto de características que seja mais representativo e que contenha a maior parte da informação útil contida nos dados originais, e dessa forma obter um conjunto de dimensão menor e mais fácil de manipular na fase de classificação. Essa por sua vez, corresponde à identificação das características como pertencentes a uma determinada classe dentre certo conjunto que pode ou não ser especificado à priori (JAIN et al., 2000).

Utilizando redes neurais, o treinamento para o reconhecimento de padrões é realizado com base nos ajustes dos pesos nas conexões para relacionar as características e classes que promovam a melhor discriminação possível. Logo, se for

apresentado à rede um novo padrão, ela deve indicar a classe que melhor o representa.

3.3.1 Classificação de Sinais EMG

No artigo publicado por Phinyomark et al. (2018), foram utilizadas vinte e seis atributos, sendo alguns deles: Valor Médio Absoluto (*Mean Absolut Value* - MAV), Largura de onda (*Waveform Lenght* – WL), Média quadrática (*Root Mean Square* - RMS), *Willison Amplitude* (WA), Valor Absoluto Integrado (*Integrated Absolute Value* – IAV), *Zero Crossing* (ZC), *Slope Sign Change* (SSC), Frequência Mediana (*Median Frequency* - MDF) e Frequência Média (*Mean Frequency* - MNF), Coeficiente Autoregressivo (*Autoregressive Coefficients* – AR). Foram feitos oito conjuntos diferentes para o agrupamento dos atributos (por exemplo, o grupo 3 era a combinação dos atributos MAV, WL, ZC, SSC, RMS e AR6). Neste, é comparado o uso de uma taxa de amostragem inferior, de 200 Hz, obtida com a braçadeira Myo® e, o uso de uma taxa de 1000 Hz para a classificação de movimentos básicos das mãos e dos dedos em sujeitos saudáveis e amputados.

Já o trabalho de Patel e Patel (2016) traz uma abordagem com seis atributos no domínio do tempo (MAV, IAV, RMS, SSC, ZC, WL) e um coeficiente autoregressivo (AR) de 3ª ordem, além do mais utilizou o método Análise Linear Discriminante (*Linear Discriminant Analysis* - LDA) para redução da dimensionalidade do vetor de atributos para a identificação de seis movimentos de membros superiores.

Em Hassan (2016), o estudo tem como objetivo mover um braço robótico com base nos sinais sEMG, obtidos também por uma braçadeira Myo®, para distinguir sete movimentos da mão. Para analisar esses sinais foi empregado um sistema de reconhecimento de padrões onde são escolhidos seis atributos no domínio do tempo (MAV, WL, RMS, AR, ZC e SSC). Foram utilizados os classificadores *Support Vector Machines* (SVM), *Linear Discriminant Analysis* (LDA) e *k-nearest neighbour* (KNN), no qual o classificador SVM tem o melhor desempenho, porém com diferença pouco significativa em relação aos outros dois.

A pesquisa realizada por Elamvazuthi et al. (2015), teve como objetivo identificar doenças neuromusculares (miopatia e neuropatia) com base nos sinais EMG por meio de classificação. Foram utilizadas cinco técnicas de extração de características, como AR, RMS, ZC, WL e MAV. Para a classificação foi utilizado o MLP. Os atributos que mostraram melhores desempenhos isoladamente foi o AR e o RMS. Os autores

realizaram cinco grupos (1- Saudável e não saudável, 2- Saudável e miopatia, 3- Saudável e neuropatia, 4- Miopatia e neuropatia e 5- Saudável, miopatia e neuropatia) para análise e comparação dos resultados com cada atributo. O último grupo obteve o melhor resultado de acurácia com o AR, de 86,3%. Os resultados com desempenhos mais baixo foi para este mesmo grupo, porém com os atributos ZC (76,3%) e WL (75,7%).

No trabalho desenvolvido por Arief et al. (2015) foi realizada uma comparação entre cinco características (MAV, VAR, WA, WL e ZC), de sinais EMG dos oito canais de uma braçadeira Myo® objetivando verificar diferenças significativas em determinados movimentos (punho com mão fechada, descanso, punhos com três dedos flexionado (polegar, médio e anelar), ponta da arma ou “L” invertido e a dobra do meio do dedo (falanges distais e médias). É testado o desempenho de cada atributo e o resultado deste estudo mostrou que a classificação das características avaliadas sempre mostram os mesmos resultados em quatro dos cinco movimentos, onde os atributos MAV e WL apresentam os melhores resultados.

O estudo de Ahsan et al (2011) descreve o processo de detecção de diferentes gestos pré-definidos (esquerda, direita, para cima e para baixo) com RNA, que são particularmente úteis para reconhecimento complexo de padrões e tarefas de classificação. As assinaturas padrão do sinal EMG são extraídas para cada movimento e, em seguida, a RNA é utilizada para classificar os sinais EMG. Foi utilizada também, uma rede de retropropagação (BP) com o algoritmo de treinamento de *Levenberg-Marquardt* para detecção de gesto. Foram empregados parâmetros baseados em tempo e frequência (MAV, RMS, VAR, SD, ZC, SSC e WL) que foram escolhidos para alimentar a rede neural.

Capítulo 4

4. METODOLOGIA E DESENVOLVIMENTO DO TRABALHO

Este capítulo detalha as estratégias utilizadas para o desenvolvimento do projeto. Aborda as principais bibliotecas virtuais utilizadas para o embasamento teórico, os dispositivos utilizados para a aquisição de dados, os movimentos escolhidos para a classificação através da RNA e as características extraídas para possibilitar o reconhecimento do padrão do gesto executado. Traz um embasamento sobre o Produto das Eficiências, curva *Receiver Operating Characteristics – ROC*, Matriz de confusão e os algoritmos *Resilient Backpropagation – Rprop* e *Levenberg-Marquardt – LM*, todos estes utilizados como abordagens sistêmicas e parâmetros para se obter o melhor classificador neural.

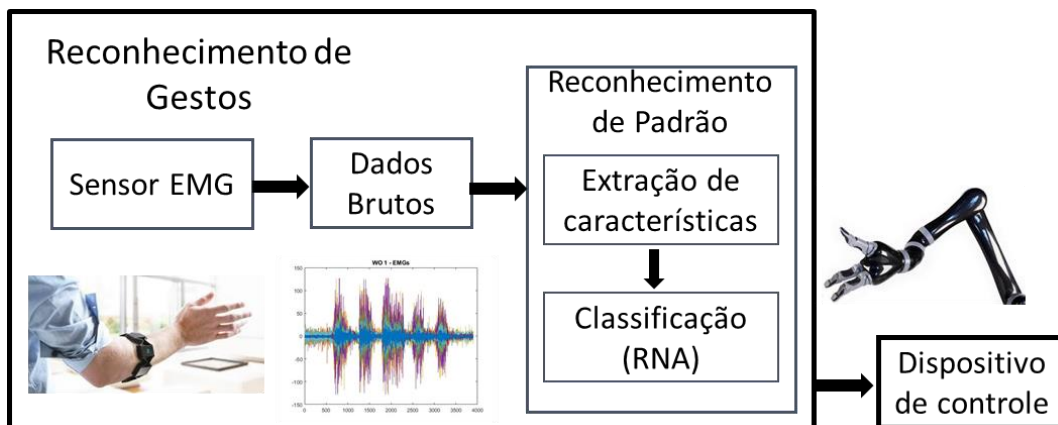
4.1 Métricas de Avaliação de Desempenho

Para a definição da abordagem sistêmica a ser aplicada para a realização do processamento dos sinais elétricos musculares foram estudadas e testadas diversas estratégias visando garantir a melhor eficiência da Rede Neural Artificial. Os sinais mioelétricos são ruidosos e complexos, portanto precisam de um processamento e uma “assinatura” que é obtida através da extração das características.

Devido à viabilidade, a facilidade de utilização do usuário e a não necessidade de gel, que no caso de muitos testes se torna um inconveniente para o usuário, optou-se por utilizar a braçadeira Myo®.

A Figura 4.1 ilustra o diagrama de blocos do processo de reconhecimento de gestos, o qual envolve um usuário vestido com abraçadeira Myo® (com os oito eletrodos), e destes eletrodos são captados os dados brutos. Após a aquisição destes dados é realizado o processamento dos sinais obtidos, como a redução de ruídos. A partir do resultado deste processamento, serão realizadas as etapas de extração de características e classificação para detectar a “assinatura” do sinal e realizar o reconhecimento do padrão. De posse das “assinaturas” necessárias, será realizado o treinamento da rede neural artificial.

Figura 4.1 – Diagrama de blocos do processo de reconhecimento de gestos.




Fonte: Autoria própria.

4.1.1 Aquisição de Sinais

A etapa de aquisição de sinais foi realizada no Laboratório de Robótica da Universidade Federal da Bahia, onde 20 alunos vestiram a braçadeira e executaram os 5 movimentos - Desvio Radial, desvio Ulnar, Mão Fechada, Mão com Bola e Mão com *Gripper* (Vide Figura 4.2) - propostos 10 vezes. A princípio foi planejado que os alunos repetissem as sequências em 5 dias diferentes, porém nem todos puderam realizar os testes em outros dias. Todos os dados foram armazenados para posterior tratamento e extração de características. Nesta situação, obteve-se um total de 2500 amostras entre os cinco movimentos, ou seja, 500 amostras de cada. Um exemplo do sinal dos oito eletrodos para o movimento de Mão com *Gripper* pode ser visualizado na Figura 4.3.

Figura 4.2 – Classes de Movimento. a) Desvio Radial b) Desvio Ulnar c) Mão Fechada d) Mão com Bola e) Mão com *Gripper*.




Fonte: Leal e Saikusa (2013). Adaptado pela autora.

A Bola e o *Gripper* utilizados na execução dos movimentos citados são ferramentas de fisioterapia para fortalecimento e reabilitação dos músculos envolvidos

no movimento da mão. Os três últimos movimentos citados (Mão fechada, Mão com Bola e Mão com *Gripper*) são de execução similar, divergindo principalmente na intensidade da força aplicada exercida na execução.

Figura 4.3 – Exemplo de Sinal EMG para teste (Mão com *Gripper*).



Fonte: Autoria própria.

Os dados brutos foram extraídos dos oito sensores EMG contidos na braçadeira e, todos eles sofreram um processamento estatístico para obtenção da “assinatura” de cada gesto. As sete características extraídas nos sinais foram calculadas com o auxílio do MATLAB e podem ser visualizadas no exemplo da Tabela 4.1: Média do Valor Absoluto (MAV), Média da Raiz Quadrática (RMS), Variância (VAR), Largura do Comprimento de Onda (WL), *Zero Crossing* (ZC), *Slop Sign Change* (SSC) e Amplitude de Willison (WA). Grupos de atributos foram combinados no intuito de se obter o melhor resultado do classificador neural através do uso de redes neurais artificiais. Após este processo, os dados foram normalizados entre zero e um, onde os sinais brutos foram divididos pelo valor máximo encontrado em cada ensaio.

Na Tabela 4.1 também é possível verificar como os dados foram organizados em cada teste e foram normalizados devido ao fato de a amplitude variar de pessoa para pessoa. Os sinais adquiridos foram pré-processados, extraindo-se as características para cada eletrodo. Considerando os 8 eletrodos disponíveis na pulseira, e as 7 variáveis extraídas, empilhando-se essas em uma mesma coluna, cada amostra possui 56 atributos, que serão as entradas para as RNA realizarem a classificação dos gestos.

Tabela 4.1 – Exemplo da extração de características dos dados brutos para o movimento Mão com *Gripper* normalizados ente 0 e 1.

Mão com <i>Gripper</i> - Pessoa 1 - Dia 1 - Teste 1								
Extração Características	Sinais EMG Normalizados							
	EMG1	EMG2	EMG3	EMG4	EMG5	EMG6	EMG7	EMG8
MAV	0,1066	0,1594	0,0949	0,1462	0,1071	0,0855	0,1131	0,0932
RMS	0,1948	0,2445	0,1772	0,2685	0,1913	0,1639	0,2407	0,2038
VAR	0,0380	0,0597	0,0314	0,0721	0,0366	0,0268	0,0580	0,0416
WL	0,1640	0,2525	0,1601	0,2495	0,1850	0,1348	0,1794	0,1481
SSC	0,4810	0,5228	0,4873	0,5671	0,5620	0,4405	0,4177	0,4076
ZC	0,6089	0,5810	0,6152	0,6544	0,6620	0,6177	0,6380	0,6278
WA	0,9582	0,9734	0,9570	0,9734	0,9582	0,9278	0,9063	0,9177

Fonte: Autoria própria.

4.1.2 Reconhecimento de Padrão de Gestos

Em estudos similares, conforme o item do capítulo anterior, 3.2.1, na extração de características para classificação de sinais EMG, foram observados o uso frequente de características no domínio do tempo, sendo este fator influenciador para a escolha das sete características trabalhadas neste projeto e descritas brevemente abaixo:

- **Média de valor absoluto (*Mean Absolute Value* - MAV):** é o valor médio retificado (ARV) e pode ser calculada utilizando a média móvel de onda completa retificada EMG (Equação 4.1). Mais especificamente, é calculada tomando a média do valor absoluto do sinal de EMG. Uma vez que representa a maneira simples de detectar os níveis de contração muscular, torna-se um recurso popular para aplicações controlada por mioelétrica. É definida como (ASHAN, 2011):

$$MAV = \frac{1}{N} \sum_{n=1}^N |x_n| \quad (4.1)$$

onde N denota o número de amostras do sinal e x_n representa o sinal EMG num segmento.

- **Média Quadrática (*Root Mean Square* - RMS):** representa a raiz quadrada da média quadrática, conforme Equação 4.2 (ASHAN, 2011):

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2} \quad (4.2)$$

- **Variância do EMG (Variance - VAR):** Variância do sinal EMG pode ser calculada através da Equação 4.3 (ASHAN, 2011):

$$VAR = \frac{1}{N-1} \sum_{n=1}^N (x_n - \bar{x})^2 \quad (4.3)$$

- **Forma de Comprimento de Onda (Waveform Length - WL):** é o comprimento acumulado da forma de onda durante o segmento do tempo considerado. WL está relacionada com a amplitude de onda, frequência e tempo. Pode ser calculada pela Equação 4.4.

$$WL = \sum_{n=1}^N |x_{n+1} - x_n| \quad (4.4)$$

- **Zero Crossing (ZC):** é o número de vezes que o valor da amplitude do sinal de EMG cruza o zero no eixo Y. Este atributo fornece uma estimativa aproximada das propriedades de domínio de frequência. E pode ser estimado pela Equação 4.5 (ASHAN, 2011):

$$ZC = \sum_{i=1}^{N-1} [sgn(x_i \times x_{i+1}) \cap |x_i - x_{i+1}| \geq limiar] \quad (4.5)$$

$$sgn(x) = \begin{cases} 1, & \text{se } x \geq limiar \\ 0, & \text{outro valor} \end{cases}$$

- **Slope Sign Change (SSC):** é o número de alterações entre a inclinação (positiva e negativa) considerando três segmentos consecutivos no sinal EMG (Equação 4.6). Um limiar é utilizado para minimizar a influência do ruído (ASHAN, 2011):

$$SSC = \sum_{i=2}^{N-1} [f[(x_i - x_{i-1}) \times (x_i - x_{i+1})]] \quad (4.6)$$

$$f(x) = \begin{cases} 1, & \text{se } x \geq limiar \\ 0, & \text{outro valor} \end{cases}$$

- **Amplitude de Willison (WA):** é o número de vezes que a diferença na amplitude do sinal EMG entre dois segmentos adjacentes excede um limite pré-definido. Pode ser calculado pela Equação 4.7.

$$WA = \sum_{i=1}^{N-1} [f|x_i - x_{i+1}|] \quad (4.7)$$
$$f(x) = \begin{cases} 1, & \text{se } x \geq \text{limiar} \\ 0, & \text{outro valor} \end{cases}$$

4.1.3 Produto das Eficiências

O produto das eficiências – PE corresponde à média geométrica das eficiências de cada classe (Equação 4.8) e tem como funcionalidade, neste caso, assim como a matriz de confusão, avaliar o desempenho das redes neurais (CRUZ,2014).

$$PE = (Ef_1 \times Ef_2 \times \dots \times Ef_n)^{1/y} \quad (4.8)$$

onde Ef_i é a eficiência de discriminação da classe i e y é o número total de classes.

4.1.4 Curva ROC

A curva ROC (*Receiver Operating Characteristics*) pode ser utilizada para visualizar, organizar e selecionar classificadores com base no seu desempenho. Podem mostrar o limiar entre taxas de acertos e falso alarme dos classificadores. Gráficos ROC tem sido usado na teoria de detecção de sinal para descrever a compensação entre taxas de acerto e taxas de alarme falso de classificadores (FAWCETT, 2005; CRUZ, 2014).

Dado um classificador e um padrão de entrada (instância), existem quatro possíveis resultados:

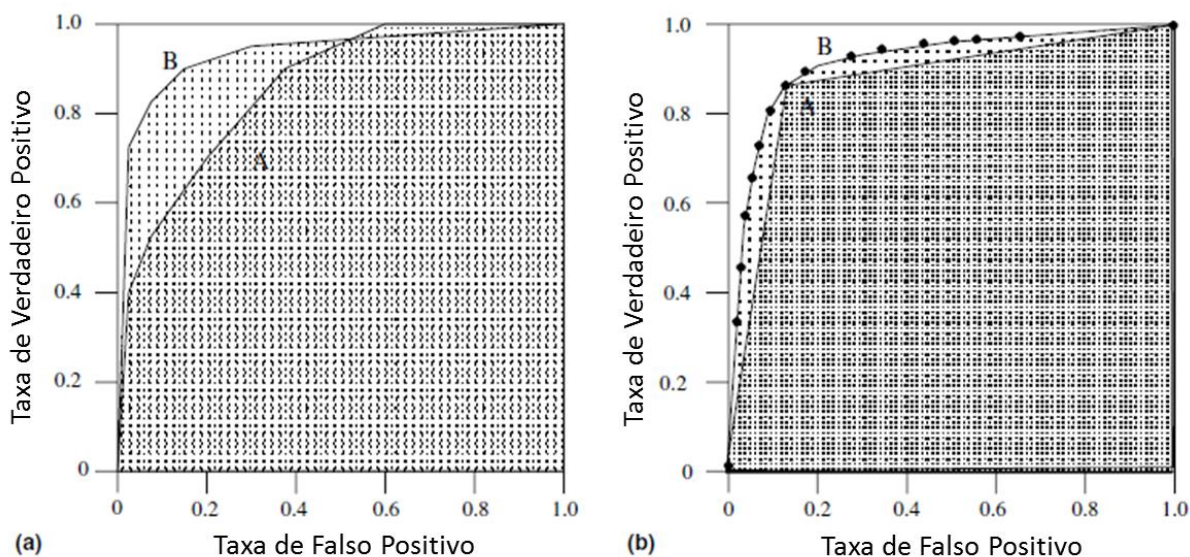
- Verdadeiro Positivo (VP) - Se a instância for positiva e classificada como positiva;
- Falso Negativo (FN) - Se a instância for positiva e for classificada como negativa;
- Verdadeiro Negativo (VN) - Se a instância for negativa e classificada como negativa;

- Falso Positivo (FP) - Se a instância é negativa e for classificado como positiva.

Os gráficos ROC são bidimensionais nos quais a Taxa de Verdadeiro Positivo é plotada no eixo X e a Taxa de Falso Positivo é plotada no eixo Y. Um gráfico ROC descreve as compensações relativas entre benefícios (verdadeiros positivos) e custos (falsos positivos).

A curva ROC mostra como as Probabilidades de Detecção (PD) e Falso Alarme (FP) variam de acordo com o patamar de decisão do discriminador. A eficiência de um classificador pode ser estimada a partir da área sob a curva ROC, quanto maior a área mais eficiente é o discriminador (SOUZA, 2015). Na Figura 4.4 é possível verificar o exemplo de dois gráficos com suas respectivas curvas / áreas, em (a) é possível verificar que a curva B possui melhor desempenho, devido à sua área ser maior que da curva A. Já em (b) é possível verificar uma aproximação entre os resultados das curvas A e B, porém B permanece com o maior domínio sob o gráfico.

Figura 4.4 – Exemplo de 2 gráficos ROC.



Fonte: FAWCETT adaptado pela autora.

Neste trabalho, as classes de interesse são compostas pelas assinaturas dos sinais EMG de cinco movimentos diferentes, porém, sendo três bem parecidos (Mão fechada, Mão com Bola e Mão com *Gripper*). Assim a Taxa de Falso positivo (TFP) é associada à probabilidade de Falso Alarme (PF), ou seja, a probabilidade de classificação de uma Classe 1 sendo classificada como outra. E a Taxa de Verdadeiro

Positivo (TVP) é associada a Probabilidade de Detecção (PD), que é a classificação correta de uma classe.

Antes de abordar o funcionamento da matriz de confusão é válido ressaltar alguns parâmetros que estão envolvidos nos cálculos dela:

- A *Taxa de Verdadeiro Positivo (TVP)*, também chamada de taxa de acerto, de um classificador é estimada como:

$$TVP \approx \frac{VP}{P} \quad (4.9)$$

onde, *VP* é a Classificação das Positivas Corretas e *P* é o Total de Positivos.

- A *Taxa de Falso Positivo (TFP)*, também chamada de falso alarme é dado por:

$$TFP \approx \frac{FP}{N} \quad (4.10)$$

onde, *FP* é a Classificação das Negativas Incorretas e *N* é o Total de Negativos.

- Precisão:

$$precisão = \frac{VP}{VP + FP} \quad (4.11)$$

- Acurácia:

$$acurácia = \frac{VP + VN}{P + N} \quad (4.12)$$

- Especificidade:

$$especificidade = \frac{VN}{FP + VN} = 1 - taxa\ fp \quad (4.13)$$

4.1.5 Matriz de Confusão

Na matriz de confusão são exibidas as probabilidades de detecção de cada classe (na diagonal principal) e erro de classificação (nos elementos fora da diagonal principal). Quando PE=1, significa que o classificador tem 100 % de exatidão para as classes em consideração (CRUZ, 2014).

Na matriz de confusão a ser trabalhada, a diagonal principal, elementos onde $i = j$, são representadas pelo número de acertos com relação ao total dedicado para testes (50% do total de amostras da classe). A matriz representada na Figura 4.5 possui 5 classes, na qual cada classe possui 250 amostras para teste, totalizando 1250 amostras. Note que ao invés de se ter uma matriz 5x5, tem-se uma 6x6, na qual a linha 6 e coluna 6 representam resultados dessa matriz.

Figura 4.5 – Exemplo de Matriz de Confusão

Matriz de Confusão

1	203 16,2%	10 0,8%	13 1,0%	4 0,3%	0 0,0%	88,3% 11,7%
2	18 1,4%	229 18,3%	4 0,3%	1 0,1%	1 0,1%	90,5% 9,5%
3	19 1,5%	7 0,6%	201 16,1%	31 2,5%	8 0,6%	75,6% 24,4%
4	5 0,4%	2 0,2%	27 2,2%	157 12,6%	42 3,4%	67,4% 32,6%
5	5 0,4%	2 0,2%	5 0,4%	57 4,6%	199 15,9%	74,3% 25,7%
	81,2% 18,8%	91,6% 8,4%	80,4% 19,6%	62,8% 37,2%	79,6% 20,4%	79,1% 20,9%
	1	2	3	4	5	

Classe Alvo

Fonte: Autoria própria.

No primeiro elemento da diagonal principal - a_{11} se encontra o valor 203, que representa o total de acertos da Classe 1 de um total de 250 amostras teste desta classe. Em a_{61} , o valor principal representa a taxa de acerto (Eq 4.9) da Classe 1, logo:

$$TVP = \frac{203}{250} = 0,812 \equiv 81,2\%$$

e o valor logo abaixo representa o valor de falso alarme (Eq. 4.10), ou seja, o valor complementar, e assim sucessivamente para as demais classes.

Já em a_{16} se obtém a precisão (Eq. 4.11) da Classe 1, e abaixo o valor complementar em termos percentual. Analisando os valores da linha 1, tem-se:

$$precisão = \frac{203}{203 + 10 + 13 + 4 + 0} = \frac{203}{230} \approx 0,883 \equiv 88,3\%$$

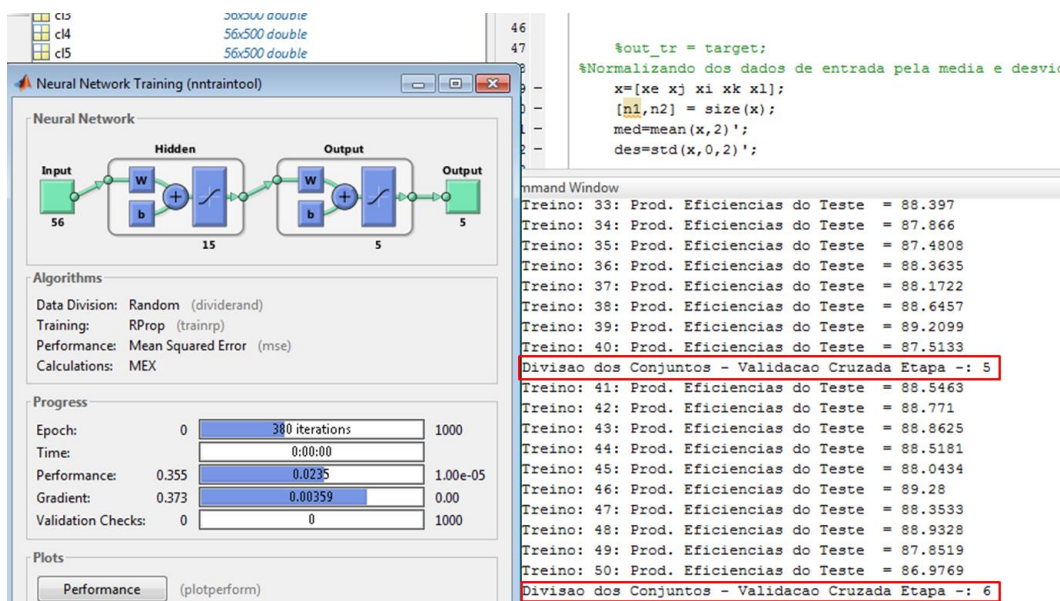
Em a_{66} , tem-se a acurácia (Eq 4.12), representando a soma dos acertos de todas as classes (valores da diagonal principal) pelo total de amostras do teste, resultando em:

$$acurácia = \frac{203 + 229 + 201 + 157 + 199}{1250} = \frac{989}{1250} = 0,791 \equiv 79,1\%$$

4.1.6 Treinamento das RNA

Para a realização dos treinamentos das RNA foram utilizados dois algoritmos, *Resilient Backpropagation* e *Levenberg-Marquardt*). A máquina de aprendizado utilizada foi uma rede MLP. Uma função foi utilizada para realizar o procedimento de validação cruzada *k-fold*. As assinaturas disponíveis para cada classe de interesse foram divididas em 10 subconjuntos e em cada sorteio são escolhidos 5 subconjuntos para treino e outros 5 para validação e teste. Um total de 10 sorteios foram realizados e para cada um deles o processo de treinamento foi reiniciado 10 vezes conforme a Figura 4.6, onde apresenta na tela do *command window* do Matlab a organização dos resultados, número de seqüência do treino, número de divisão dos conjuntos na validação cruzada. Deste modo, pretende-se explorar melhor a estatística disponível e também diminuir a chance do treinamento convergir para um mínimo local. Vale ressaltar que a tela apresentada do lado esquerdo da imagem foi chamada no programa apenas para acompanhamento das iterações realizadas.

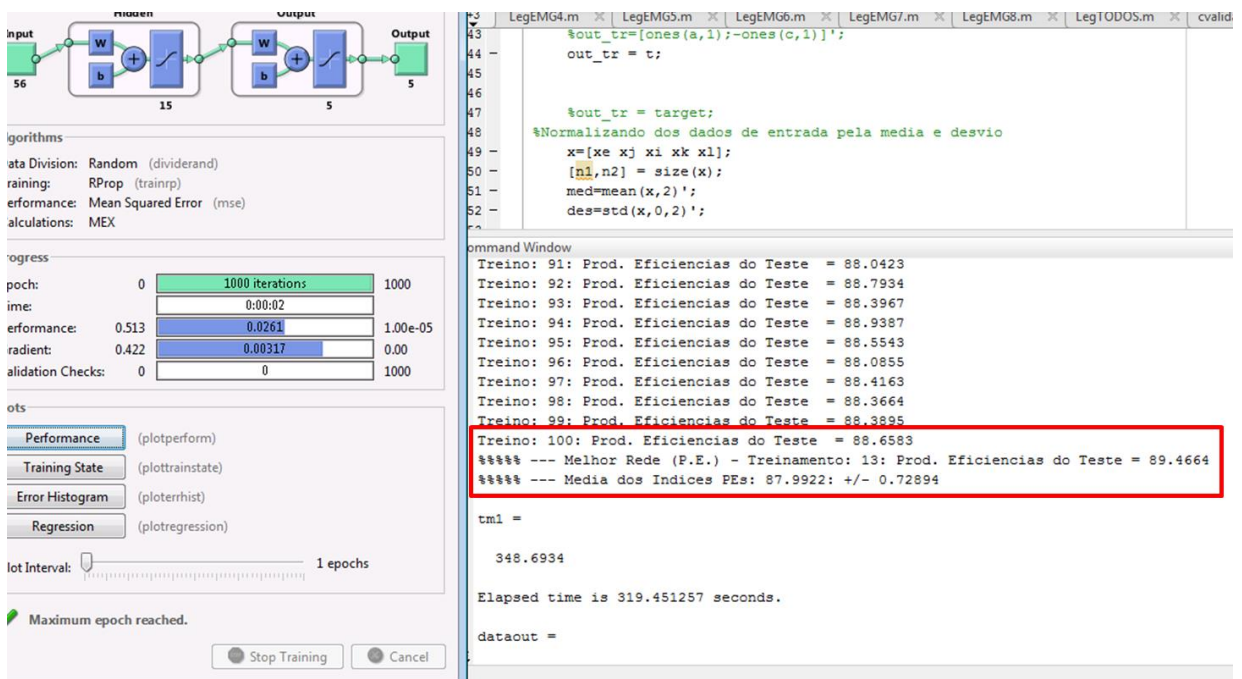
Figura 4.6 – Tela de treinamento da rede neural: divisão dos subconjuntos.



Fonte: Autoria própria.

A Figura 4.7 apresenta o resumo do resultado final após os 100 treinos, no qual apresenta o melhor o treino em que se obteve o melhor produto das eficiências, o valor dele, a média entre os 100 PEs e o desvio padrão. No exemplo desta figura, pode-se perceber que o melhor resultado obtido foi no treino 13, com um PE de aproximadamente 89,47%, média dos PEs de 87,99% entre os 100 treinos e um desvio padrão de 0.7289%.

Figura 4.7 – Tela de treinamento da rede neural: Resultado.



Fonte: Autoria própria.

A Figura 4.8 apresenta a tabela com todos os 100 resultados armazenados numa pasta de saída chamada de 'dataout' e mostra o resultado do melhor treino, baseando-se no valor do produto das eficiências.

A utilização de algoritmos de treinamento distintos teve o objetivo de verificar se há influência significativa do algoritmo de treinamento no desempenho final do sistema.

Vale ressaltar que os treinos foram realizados de posse do mesmo processador (Intel® Core™ i7 3610QM 2.3GHz), uma vez que o tempo de processamento é utilizado para a realização de comparação.

Figura 4.8 – Tela de treinamento da rede neural: Melhor treino.

The screenshot displays the MATLAB Neural Network Training interface. The main window shows a table of training results for iterations 98 to 102. The 'indnet' column for iteration 101 is circled in red, indicating the best training iteration. Below the table, the Command Window shows the training progress and the final results.

Iteration	Prod. Eficiencias do Teste
98	88.3664
99	88.3895
100	88.6583
101	89.4664
102	

```

Command Window
Treino: 91: Prod. Eficiencias do Teste = 88.0423
Treino: 92: Prod. Eficiencias do Teste = 88.7934
Treino: 93: Prod. Eficiencias do Teste = 88.3967
Treino: 94: Prod. Eficiencias do Teste = 88.9387
Treino: 95: Prod. Eficiencias do Teste = 88.5543
Treino: 96: Prod. Eficiencias do Teste = 88.0855
Treino: 97: Prod. Eficiencias do Teste = 88.4163
Treino: 98: Prod. Eficiencias do Teste = 88.3664
Treino: 99: Prod. Eficiencias do Teste = 88.3895
Treino: 100: Prod. Eficiencias do Teste = 88.6583
Treino: 101: Prod. Eficiencias do Teste = 88.6583
**** --- Melhor Rede (P.E.) - Treinamento: 13: Prod. Eficiencias do Teste = 89.4664
**** --- Media dos Indices PEs: 87.9922: +/- 0.72894

tml =

    348.6934
    
```

Fonte: Autoria própria.

Capítulo 5

5. RESULTADOS

Foram realizados vários testes de Treinamento da RNA para cinco classes de movimentos (Desvio Ulnar, Desvio Radial, Mão Fechada, Mão com Bola e Mão com *Gripper*), visando encontrar resultados com a melhor acurácia.

Apesar de em publicações anteriores (FONSECA, 2017 e 2018), os resultados mostrarem que o atributo WL influenciava negativamente a acurácia da rede neural, outras estratégias foram realizadas visando um resultado ainda melhor, uma vez que o desafio aumentou, utilizando cinco classes, tendo três delas, grupos de ativação muscular bem semelhantes.

Doze combinações de características (Tabela 5.1) foram utilizadas para alimentar os classificadores, estabelecendo-se um método quantitativo de análise da relevância desses atributos para o problema. Além disto, cada grupo de características foi testado para classificadores com 5, 10 e 15 neurônios na camada oculta e treinados com 500 e com 1000 épocas em cada rodada, totalizando 72 treinamentos para cada algoritmo de treinamento.

Tabela 5.1 – Grupos com as características para alimentação dos classificadores.

Grupo	Características
G1	Todas: MAV, RMS, VAR, WL, ZC, SSC e WA
G2	Exceto MAV
G3	Exceto RMS
G4	Exceto VAR
G5	Exceto WL
G6	Exceto ZC
G7	Exceto SSC
G8	Exceto WA
G9	Exceto WL e SSC
G10	Exceto WL e WA
G11	Exceto RMS, SSC e WA
G12	Exceto RMS, WL e ZC

Fonte: Autoria Própria

A seguir é apresentado o resumo dos resultados de cada treinamento considerando cada um dos grupos de atributos especificados. São mostradas e comparadas as matrizes de confusão e curvas ROC do melhor resultado

encontrado, levando-se em consideração o resultado global da matriz, a acurácia (Equação 4.12).

De acordo com a Tabela 5.2 é possível verificar que para o conjunto com todos os atributos, o melhor desempenho foi obtido com a combinação de 15 neurônios na camada oculta e 500 épocas de treinamento. Os piores resultados foram no treinamento com Rprop utilizando-se 5 neurônios e 500 épocas, tendo como acurácia 78,6% e, para o treinamento com LM quando se utiliza 5 neurônios e 1000 épocas.

A Matriz de Confusão da Figura 5.1 apresenta a acurácia do treinamento e a comparação entre os algoritmos Rprop e LM. É possível verificar que a Classe 2 nos dois casos possui a melhor precisão e que a acurácia dos classificadores possui resultados muito similares, Rprop com 82,4% e LM com 82,6%.

Na Figura 5.2 é possível verificar uma coerência com os resultados na matriz de confusão, no qual a Classe 2 apresenta a maior área sob o gráfico da curva ROC, significando maior eficiência, conforme visto no capítulo anterior. Podendo-se perceber, também, que nas curvas representadas no algoritmo RProp, as Classes 3 e 4 possuem uma taxa de Falso Positivo maior. Já no LM, as classes possuem gráficos similares, apresentando pequenas variações, também é possível notar que os gráficos das Classes 3, 4 e 5 ficam bem próximos evidenciando o erro de classificação devido à similaridade destas classes.

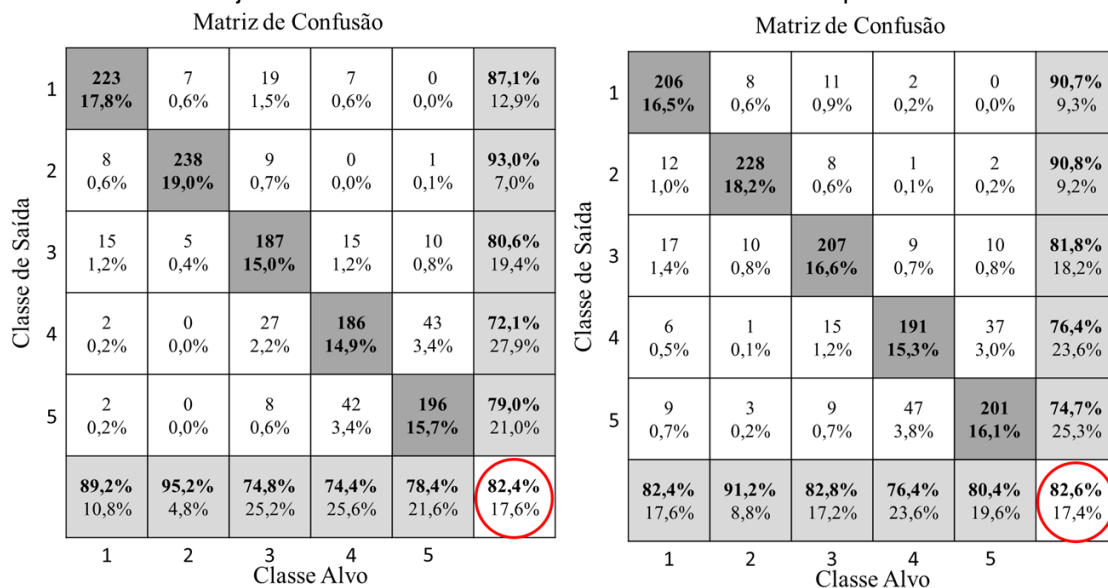
Outra consideração a ser verificada é com relação ao tempo de processamento do treinamento, sendo o necessário um tempo muito superior do LM comparado ao Rprop em todos os resultados.

Tabela 5.2 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto com Todas as características.

Grupo	NH	Época	Rprop				LM			
			Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]	Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]
G1	5	500	2,96	89,1	78,6	90,8 / 2	49,60	88,1	78,12	87,2 / 2
	10		3,19	89,5	79,6	89,8 / 2	289,24	88,4	79,9	88,2 / 2
	15		3,41	89,9	82,4	93,0 / 2	596,81	89,5	82,6	91,2 / 2
	5	1000	4,20	89,5	79,6	90,7 / 2	168,34	86,5	77,7	85,2 / 2
	10		4,67	89,7	80,2	90,4 / 2	580,98	88,3	78,7	90,4 / 2
	15		5,13	89,3	79,8	87,6 / 2	1251,96	89,6	82,1	91,6 / 2

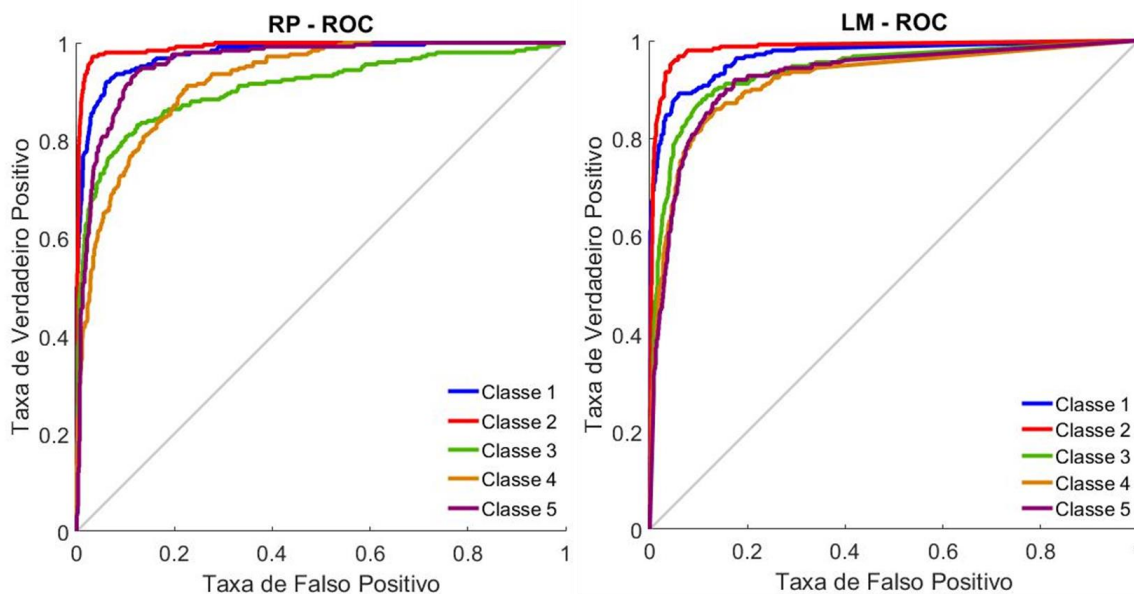
Fonte: Autoria própria.

Figura 5.1 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto com Todas as características – 15NH – 500 épocas.



Fonte: Autoria própria.

Figura 5.2 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto com Todas as características – 15NH – 500 épocas.



Fonte: Autoria própria

Na tabela Tabela 5.3 é possível verificar que o melhor resultado com o classificador Rprop foi obtido com 10 neurônios na camada oculta e 1000 épocas de treinamento, resultando em 81,5% de acurácia e 94% de precisão da Classe 2. Já o classificador LM, obteve melhor resultado com 15 neurônios e 1000 épocas, tendo como resposta 81,7% de acurácia e 90,8% de precisão da Classe 2. Logo, pode-se perceber que o LM teve um resultado um pouco melhor do que o Rprop em termos de

acurácia, porém com tempo de processamento muito superior para uma diferença tão pequena.

A Figura 5.3 apresenta a acurácia do treinamento e a comparação entre os algoritmos Rprop e LM para um mesmo conjunto. Devido ao fato de acurácia no LM ter sido melhor, a comparação entre as matrizes se dá com relação ao mesmo grupo, quantidade de neurônios na camada oculta e épocas de treinamento deste classificador, ou seja, com 15 neurônios e 1000 épocas. É possível verificar que a Classe 2 nos dois casos possui a melhor precisão e que a acurácia dos classificadores possui resultados muito similares, Rprop com 81,4% e LM com 81,7%.


Na Figura 5.4, utilizando-se a referência do melhor resultado (Tabela 5.3), é possível verificar uma coerência com os resultados na matriz de confusão, no qual a Classe 2 apresenta a maior área sob o gráfico da curva ROC em ambos classificadores. Podendo-se perceber, também, que o pior resultado, observando-se o gráfico RP, foi para a Classe 3 com uma Taxa de Verdadeiro Positivo consideravelmente menor com relação as demais. No LM é possível notar que as curvas são muito parecidas, principalmente quando se observa as Classes 3 e 5.

Tabela 5.3 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem a característica MAV.

Grupo	NH	Época	Rprop				LM			
			Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]	Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]
G2	5	500	7,06	88,0	76,7	89,6 / 2	79,02	85,8	75,4	82,8 / 2
	10		7,84	88,9	78,8	92,0 / 2	255,22	87,6	79,2	94,0 / 2
	15		8,82	89,3	81,0	87,6 / 2	513,64	88,3	79,3	87,6 / 2
	5	1000	12,14	88,3	77,8	91,6 / 2	163,22	86,8	77,8	90,8 / 2
	10		12,75	89,8	81,5	94,0 / 2	511,11	87,4	77,4	89,2 / 2
	15		14,12	89,3	81,4	92,8 / 2	1076,38	89,6	81,7	90,8 / 2


Fonte: Autoria própria.

Figura 5.3 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem a característica MAV – 15 NH – 1000 épocas.



Fonte: Autoria própria.

Figura 5.4 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem a característica MAV – 15 NH – 1000 épocas.



Fonte: Autoria própria.

Conforme pode ser visto na Tabela 5.4, o conjunto de características no qual se excluiu o RMS, o melhor desempenho foi para o Rprop com 15 neurônios e 500 épocas, atingindo 81,0% de acurácia e a melhor precisão na Classe 2.

A Figura 5.5 mostra a comparação entre os dois algoritmos para esta configuração, na qual a acurácia com o Rprop é de 81% e do LM, de 79,2%. Nesta comparação, pode-se notar que o fato de uma Classe ter maior Taxa de Verdadeiro

Positivo, não significa que tenha a melhor precisão, como pode ser visto na matriz do classificador Rprop. A Classe 2 tem a maior TVP, porém é a Classe 1 que obteve a melhor precisão. Outro dado que chama atenção, é o declínio da TVP na Classe4, apenas de 68%.

Observando as curvas ROC da Figura 5.6 é possível verificar nos dois casos a eficiência da Classe 2. Nos gráficos visto em RP, as Classes 1 e 2 estão muito próximas e a Classe 4 evidencia o pior resultado, reiterando o resultado visto na matriz. As Classes 3 e 5 tem gráficos praticamente idênticos nos dois classificadores.

Tabela 5.4 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem a característica RMS.

Grupo	NH	Época	Rprop				LM			
			Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]	Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]
G3	5	500	2,87	87,5	76,8	91,6 / 2	225,09	86,4	76,2	84,0 / 2
	10		3,12	88,8	78,8	89,6 / 2	644,57	88,0	79,0	84,8 / 2
	15		3,40	89,1	81,0	89,6 / 2	1431,13	88,3	79,2	87,2 / 2
	5	1000	4,28	87,7	77,2	85,6 / 2	389,04	86,4	76,2	86,8 / 1
	10		4,70	88,5	79,0	87,6 / 2	1299,90	88,2	78,6	88,0 / 2
	15		5,09	88,9	80,0	88,4 / 2	599,75	89,0	79,6	90,8 / 1


Fonte: Autoria própria.

Figura 5.5 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem a característica RMS – 15NH – 500 épocas.

Matriz de Confusão						Matriz de Confusão									
1	213 17,0%	13 1,0%	10 0,8%	0 0,0%	1 0,1%	89,9% 10,1%	1	210 17,0%	16 1,3%	10 0,8%	1 0,1%	0 0,0%	88,6% 11,4%		
	2	16 1,3%	224 17,9%	10 0,8%	1 0,1%	3 0,2%		88,2% 11,8%	2	13 1,0%	218 17,4%	11 0,9%	0 0,0%	0 0,0%	90,1% 9,9%
		3	15 1,2%	11 0,9%	207 16,6%	19 1,5%		6 0,5%		80,2% 19,8%	3	18 1,4%	9 0,7%	193 15,4%	14 1,1%
	4		6 0,5%	2 0,2%	12 1,0%	170 13,6%		42 3,4%	73,3% 26,7%	4		4 0,3%	3 0,2%	24 1,9%	175 14,0%
		5	0 0,0%	0 0,0%	11 0,9%	60 4,8%		198 15,8%	73,6% 26,4%		5	5 0,4%	4 0,3%	12 1,0%	60 4,8%
	85,2% 14,8%							87,2% 12,8%							
89,6% 10,4%						87,2% 12,8%									
82,8% 17,2%						77,2% 22,8%									
68,0% 32,0%						70,0% 30,0%									
79,2% 20,8%						77,6% 22,4%									
81,0% 19,0%						79,2% 20,8%									
1						1									
2						2									
3						3									
4						4									
5						5									
Classe Alvo						Classe Alvo									

Fonte: Autoria própria.

Figura 5.6 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem a característica RMS – 15NH – 500 épocas.



Fonte: Autoria própria.

Na Tabela 5.5 são apresentados os resultados para o Grupo 4 de atributos, que representa a exclusão da variância VAR, na qual mostra que o melhor desempenho foi para o LM com 15 neurônios na camada oculta e 500 épocas de treino, obtendo uma acurácia de 82,3%. Para estes mesmos parâmetros de entrada, o Rprop obteve 79,5%. A Classe 2 obteve novamente a melhor precisão, exceto para o treinamento com o Rprop com 10 neurônios e 1000 épocas, nesta situação foi a Classe 1 que obteve o melhor resultado.

Tabela 5.5 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem a característica VAR.

Grupo	NH	Época	Rprop				LM			
			Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]	Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]
G4	5	500	7,61	89,1	78,3	90,4 / 2	80,57	86,2	75,5	82,8 / 2
	10		8,24	89,9	81,0	90,4 / 2	263,20	87,4	78,5	91,6 / 2
	15		9,30	89,6	79,5	89,2 / 2	505,81	89,0	82,3	95,2 / 2
	5	1000	11,04	88,8	77,4	87,6 / 2	158,57	87,3	78,4	88,4 / 2
	10		12,22	89,3	80,2	89,6 / 1	493,60	88,0	78,3	86,0 / 2
	15		13,01	89,3	81,4	94,4 / 2	1011,83	89,1	81,0	86,0 / 2

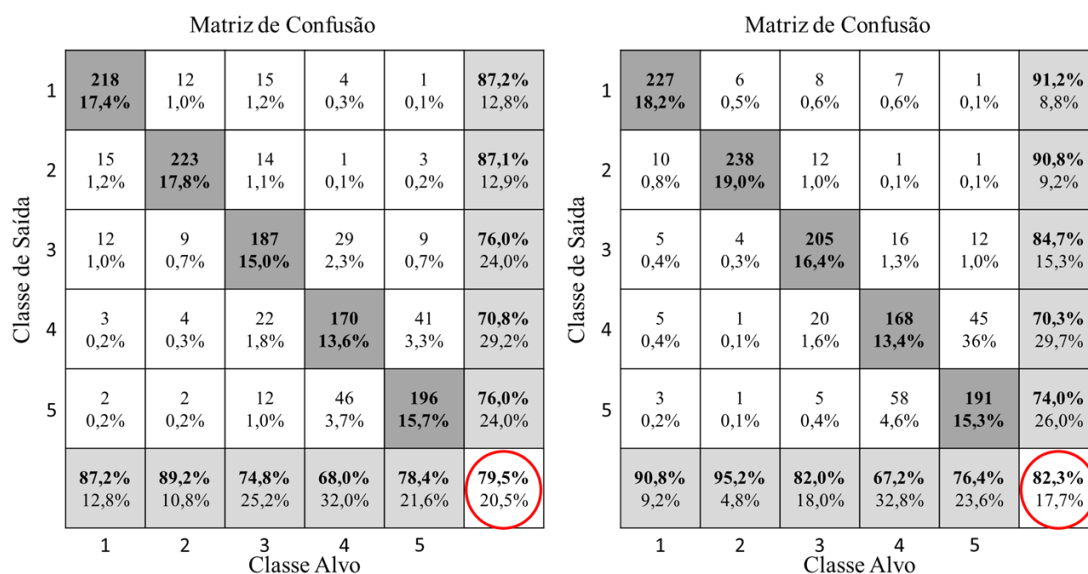
Fonte: Autoria própria

As matrizes de confusão da Figura 5.7 mostram em ambos os casos, que a Classe 2 obteve a melhor TVP, ou seja, mais amostras classificadas corretamente

dentre o total de amostras positivas. Porém a Classe 1 que obteve a melhor precisão. Evidenciam o baixo resultado da Classe 4 e como ela é classificada erroneamente como Classe 5.


A Figura 5.8 apresenta as curvas ROC para os dois comparadores, na qual é possível verificar no LM, curvas quase idênticas para as Classes 1 e 2 e o pior resultado é apresentado no gráfico da Classe 4.

Figura 5.7 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem a característica VAR – 15 NH – 500 épocas.



Fonte: Autoria própria.

Figura 5.8 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem a característica VAR – 15 NH – 500 épocas.



Fonte: Autoria própria.

Na Tabela 5.6 estão reunidos os resultados dos treinamentos utilizando os dois algoritmos, porém para o grupo em que o WL é excluído do conjunto de atributos. De todos os testes realizados para este grupo, o melhor resultado foi com o LM com 15 neurônios e 1000 épocas, obtendo-se um resultado de 81,4% de acurácia. A Classe 2 aparece como a melhor na maioria dos treinos, porém a Classe 1 surge mais precisa em dois treinos, com Rprop sendo treinada com 15 neurônios e 500 épocas e, com LM sendo treinado com 10 neurônios e 1000 épocas.

A Figura 5.9 apresenta as matrizes de confusão das comparações entre o Rprop e o LM para o mesmo grupo G5 com mesma quantidade de neurônios e épocas. A matriz do Rprop apresenta a Classe 2 com melhor TVP e a Classe 1 com a melhor precisão, também se pode notar que as Classes 3, 4 e 5 obtiveram respostas semelhantes com relação à TVP, porém diferentes com relação à precisão. As Classes 4 e 5 obtiveram o maior percentual de amostras classificadas de forma errada.


Observando os resultados através das curvas ROC (Figura 5.10), o LM possui o melhor resultado, mostrando a Classe 2 como a melhor, as Classes 3 e 5 quase idênticas e a Classe 4 com o pior resultado.

Tabela 5.6 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem a característica WL.

Grupo	NH	Época	Rprop				LM			
			Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]	Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]
G5	5	500	3,07	89,0	77,8	89,6 / 2	40,81	86,3	76,9	87,2 / 2
	10		3,38	89,6	80,5	89,2 / 2	133,64	87,9	79,5	86,4 / 2
	15		3,71	89,4	80,4	89,6 / 1	298,11	89,1	81,0	91,2 / 2
	5	1000	4,40	89,0	79,0	93,2 / 2	77,09	86,9	74,9	82,8 / 2
	10		4,79	89,6	80,3	90,8 / 2	275,04	88,1	79,0	90,4 / 1
	15		5,09	89,4	80,2	92,0 / 2	566,91	89,1	81,4	89,6 / 2


Fonte: Autoria própria

Figura 5.9 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem a característica WL – 15 NH – 1000 épocas.



Fonte: Autoria própria.

Figura 5.10 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem a característica WL – 15 NH – 1000 épocas.



Fonte: Autoria própria.

O Grupo 6 é trabalhado com a exclusão do atributo ZC, conforme a Tabela 5.7, que apresenta todos os resultados dos treinos realizados com este conjunto de atributos. Nota-se que o melhor resultado foi para a mesma configuração nos dois classificadores, 15 neurônios e 1000 épocas, obtendo o LM um resultado de acurácia um pouco melhor, 88,4% contra 88,2% do Rprop. A Classe 1 obteve 100% de TVP e precisão nos dois casos.

Na Figura 5.11 é possível verificar que o melhor desempenho foi obtido com a Classe 1 e o pior, com a Classe 4.

A curva ROC (Figura 5.12) mostra com clareza a totalidade da área do gráfico para a Classe 1, a Classe 2 com um desempenho muito próximo do ideal e, novamente, a Classe 4 com o resultado mais baixo.

Tabela 5.7 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem a característica ZC.

Grupo	NH	Época	Rprop				LM			
			Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]	Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]
G6	5	500	7,32	92,4	84,5	99,2 / 1	78,27	90,7	84,4	99,6 / 1
	10		7,39	93,1	86,7	100,0/1	125,80	92,4	87,1	99,2 / 1
	15		8,19	93,0	88,0	100,0/1	294,97	93,0	87,1	99,6 / 1
	5	1000	11,08	92,5	85,9	100,0/1	142,80	90,8	83,4	100,0/1
	10		12,28	93,3	87,0	100,0/1	498,37	93,3	87,9	99,2 / 1
	15		13,44	93,5	88,2	100,0/1	1032,71	93,4	88,4	100,0/1


Fonte: Autoria própria.

Figura 5.11 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem ZC – 15NH – 1000 épocas.

		Matriz de Confusão																	
Classe de Saída	1	250 20%	0 0,0%	0 0,0%	0 0,0%	0 0,0%	0 0,0%	100,0% 0,0%	Classe de Saída	1	250 20%	0 0,0%	0 0,0%	0 0,0%	0 0,0%	100,0% 0,0%			
	2	0 0,0%	244 19,5%	10 0,8%	0 0,0%	2 0,2%	95,3% 4,7%	Classe de Saída		2	0 0,0%	238 19,0%	9 0,7%	0 0,0%	1 0,1%	96,0% 4,0%			
	3	0 0,0%	3 0,2%	213 17,0%	18 1,4%	5 0,4%	89,1% 10,9%			Classe de Saída	3	0 0,0%	8 0,6%	219 17,5%	17 1,4%	2 0,4%	89,0% 11,0%		
	4	0 0,0%	3 0,2%	17 1,4%	187 15,0%	34 2,7%	77,6% 22,4%				Classe de Saída	4	0 0,0%	2 0,2%	11 0,9%	188 15,0%	37 3,0%	79,0% 21,0%	
	5	0 0,0%	0 0,0%	10 0,8%	45 3,6%	209 16,7%	79,2% 20,8%					Classe de Saída	5	0 0,0%	2 0,2%	10 0,8%	45 3,6%	210 16,8%	78,4% 21,6%
		100,0% 0,0%	97,6% 2,4%	85,2% 14,8%	74,8% 25,2%	83,6% 16,4%	88,2% 11,8%							100,0% 0,0%	95,2% 4,8%	87,6% 12,4%	75,2% 24,8%	84,0% 16,0%	88,4% 11,6%
	1	2	3	4	5		1		2				3	4	5				
	Classe Alvo						Classe Alvo												

Fonte: Autoria própria.

Figura 5.12 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem ZC – 15NH – 1000 épocas.



Fonte: Autoria própria.

O Grupo 7 é caracterizado pela ausência do atributo SSC. Conforme a Tabela 5.8, o melhor resultado encontrado foi no Rprop com 15 neurônios e 500 épocas, 82,6% de acurácia e a Classe 2 com o melhor desempenho. O pior resultado deste grupo foi no treino com LM com 5 neurônios e 500 épocas, obtendo 74,6% de acurácia.

A Figura 5.13 mostra as matrizes de confusão de ambos os algoritmos para o conjunto de atributos sem SSC, 15 neurônios e 500 épocas, na qual é possível perceber resultados muito semelhantes entre os dois classificadores.


Tabela 5.8 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem a característica SSC.

Grupo	NH	Época	Rprop				LM			
			Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]	Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]
G7	5	500	7,60	88,7	78,1	92,4 / 2	78,22	87,4	74,6	85,2 / 2
	10		8,28	90,0	81,7	91,6 / 2	260,98	88,4	80,7	86,8 / 2
	15		8,71	89,5	82,6	92,8 / 2	484,72	89,7	81,4	91,2 / 2
	5	1000	11,00	88,9	78,2	93,6 / 2	142,89	86,8	78,2	90,8 / 2
	10		12,45	89,7	81,6	94,4 / 2	511,14	88,7	78,6	88,8 / 1
	15		13,29	89,5	82,1	91,6 / 2	1017,60	89,4	82,5	90,8 / 2

Fonte: Autoria própria


Apesar de se ter um resultado melhor em termos de valores com Rprop, a Figura 5.14 mostra um padrão de curvas melhor para o classificador LM. Neste, as Classes 1 e 2 possuem gráficos próximos e as Classes 3,4 e 5 resultados semelhantes. Já no gráfico do RP, apresenta a Classe 5 se aproximando das Classes 1 e 2.

Figura 5.13 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem a característica SSC – 15 NH – 500 épocas.



Fonte: Autoria própria.

Figura 5.14 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem a característica SSC – 15 NH – 500 épocas.



Fonte: Autoria própria.

No Grupo 8 é possível verificar os resultados dos treinos realizados ao se excluir apenas o WA. A Tabela 5.9 apresenta o Rprop com o melhor resultado com 15 neurônios e 500 épocas, no qual se obteve acurácia de 85% e no LM para a mesma configuração, o resultado foi de 83,4%.

A Figura 5.15 apresenta as matrizes de confusão referente a configuração que se obteve o melhor resultado. Nos dois casos a Classe 2 possui a melhor TVP e a Classe 1 aparece como a classe com melhor precisão.

As curvas ROC apresentadas na Figura 5.16 mostram o melhor desempenho com o classificador RP e as curvas das Classes 1 e 5 muito próximas.

Tabela 5.9 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem a característica WA.

Grupo	NH	Época	Rprop				LM			
			Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]	Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]
G8	5	500	7,53	88,7	78,4	90,8 / 2	77,49	87,1	75,4	87,2 / 1
	10		7,85	89,3	80,5	93,2 / 2	252,80	89,5	82,3	90,0 / 2
	15		8,25	90,9	85,0	96,0 / 2	289,21	90,2	83,4	94,0 / 2
	5	1000	10,53	89,3	78,6	92,0 / 2	76,89	87,2	78,1	90,0 / 2
	10		12,68	89,9	81,2	93,6 / 2	277,38	88,8	81,0	91,2 / 2
	15		13,56	89,7	81,4	91,2 / 2	592,34	89,7	81,1	88,8 / 2


Fonte: Autoria própria.

Figura 5.15 - Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem a característica WA – 15 NH – 500 épocas.

Matriz de Confusão							Matriz de Confusão							
Classe de Saída	1	225 18,0%	8 0,6%	8 0,6%	1 0,1%	0 0,0%	93,0% 7,0%	1	229 18,3%	5 0,4%	13 1,0%	3 0,2%	0 0,0%	91,6% 8,4%
	2	9 0,7%	240 19,2%	11 0,9%	2 0,2%	1 0,1%	91,3% 8,7%	2	11 0,9%	235 18,8%	19 1,5%	0 0,0%	1 0,1%	88,3% 11,7%
	3	9 0,7%	1 0,1%	210 16,8%	22 1,8%	4 0,3%	85,4% 14,6%	3	5 0,4%	6 0,5%	201 16,1%	22 1,8%	9 0,7%	82,7% 17,3%
	4	4 0,3%	1 0,1%	13 1,0%	174 13,9%	31 2,5%	78,0% 22,0%	4	2 0,2%	0 0,0%	8 0,6%	186 14,9%	48 3,8%	76,2% 23,8%
	5	3 0,2%	0 0,0%	8 0,6%	51 4,1%	214 17,1%	77,5% 22,5%	5	3 0,2%	4 0,3%	9 0,7%	39 3,1%	192 15,4%	77,7% 22,3%
			90,0% 10,0%	96,0% 4,0%	84,0% 16,0%	69,6% 30,4%	85,6% 14,4%	85,0% 15,0%		91,6% 8,4%	94,0% 6,0%	80,4% 19,6%	74,4% 25,6%	76,8% 23,2%
		1	2	3	4	5		1	2	3	4	5		
		Classe Alvo						Classe Alvo						

Fonte: Autoria própria.

Figura 5.16 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem a característica WA – 15 NH – 500 épocas.



Fonte: Autoria própria.

O Grupo 9 é formado por 5 características, uma vez que os atributos WL e SSC foram retirados. Na Tabela 5.10 podem ser vistos todos os resultados dos treinamentos realizados com este grupo, notando-se o melhor resultado quando o classificador Rprop é treinado com 10 neurônios e 500 épocas, obtendo um resultado de 82,3% de acurácia. Pode-se verificar que o Produto das Eficiências tem valores próximos em todos os testes. A Classe 2 tem o melhor resultado, exceto para o valor mais elevado encontrado no LM, quando este é treinado com 15 neurônios e 1000 épocas.

Tabela 5.10 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem as características WL e SSC.

Grupo	NH	Época	Rprop				LM			
			Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]	Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]
G9	5	500	3,02	88,3	76,6	88,4 / 2	34,02	87,5	77,9	87,2 / 2
	10		3,54	89,8	82,3	93,2 / 2	102,06	88,0	80,0	86,8 / 2
	15		3,40	89,3	81,4	90,8 / 2	209,14	88,9	80,8	89,2 / 2
	5	1000	4,39	89,3	78,6	93,2 / 2	63,93	86,8	77,8	88,8 / 2
	10		4,62	89,6	80,5	92,8 / 2	195,72	88,3	78,2	85,6 / 2
	15		5,52	89,3	80,3	89,6 / 2	401,02	89,0	81,5	90,4 / 1


Fonte: Autoria própria.

As matrizes de confusão com o melhor resultado do G8, expostas na Figura 5.17, comparam esses dois classificadores para os mesmos parâmetros iniciais que resultou no melhor resultado, ou seja, treinos com 10 neurônios na camada oculta e

500 épocas. Pode-se perceber que a Classe 2 em ambos os casos tem a melhor taxa de verdadeiro positivo e a melhor precisão. Nota-se que para os classificadores ainda é confuso classificar as Classes 4 e 5.


Na Figura 5.18 são apresentadas as curvas ROC dos dois classificadores, na qual mostra os gráficos das Classes 3, 4 e 5 muito próximos no RP, já no LM as Classes 1 e 5 possuem curvas similares. A Classe 2 aparece com o melhor desempenho nas duas situações.

Figura 5.17 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem as características WL e SSC – 10 NH – 500 épocas.



Fonte: Autoria própria.

Figura 5.18 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem as características WL e SSC – 10 NH – 500 épocas.



Fonte: Autoria própria.

No Grupo 10 são excluídas as características WL e WA. Os resultados dos treinamentos realizados com este grupo podem ser visualizados na Tabela 5.11, onde pode ser percebido que os melhores valores de acurácia foram com as mesmas configurações de entrada para os classificadores, quando treinados com 15 neurônios e 1000 épocas, tendo LM um resultado melhor com 82,2%, porém com uma diferença pouco significativa com relação ao Rprop, que obteve 81,9% de acurácia.

As matrizes de confusão encontradas na Figura 5.19 correspondem a configuração do melhor desempenho encontrado. É possível notar que a Classe 3, quando observada a matriz do Rprop, possui TVP com valores próximo aos das Classes 4 e 5, porém, a precisão se mostra com valores mais próximos das Classes 1 e 2. Quando analisada a matriz do LM, esta classe se afasta das Classes 4 e 5 tanto em relação ao TVP, quanto em relação à acurácia. Ainda observando esta matriz, percebe-se a baixa eficiência da Classe 4, com TVP de 69,6%.


Os gráficos apresentados na Figura 5.20 com as curvas ROC da configuração anterior, reitera o fato da Classe 3, no RP, estar mais próxima às Classes 4 e 5, como visto na matriz, com relação à taxa de verdadeiro positivo. Já no LM, esta classe se aproxima das Classes 1 e 2.

Tabela 5.11 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem as características WL e WA.

Grupo	NH	Época	Rprop				LM			
			Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]	Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]
G10	5	500	2,97	88,6	77,3	90,0 / 2	30,69	86,8	76,7	85,6 / 2
	10		3,25	89,1	79,6	91,2 / 2	196,41	88,4	78,2	85,2 / 2
	15		3,49	89,8	80,6	90,0 / 2	383,31	88,9	81,1	89,2 / 1
	5	1000	4,37	89,0	78,2	88,4 / 2	131,92	88,2	79,0	92,4 / 2
	10		4,60	89,6	80,3	92,0 / 2	373,79	88,4	79,4	89,6 / 1
	15		5,08	90,2	81,9	92,4 / 2	749,11	89,0	82,2	93,6 / 2

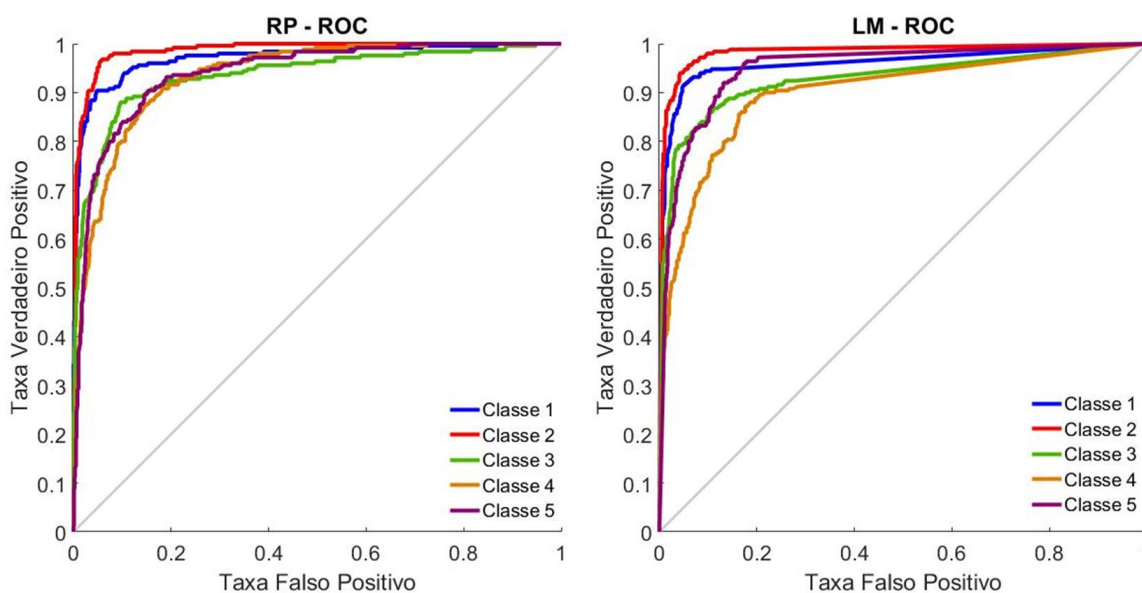
Fonte: Autoria própria.

Figura 5.19 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem as características WL e WA – 15 NH – 1000 épocas: melhor resultado.



Fonte: Autoria própria.

Figura 5.20 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem as características WL e WA – 15 NH – 1000 épocas: melhor resultado.



Fonte: Autoria própria.

O Grupo 11 é formado por 5 atributos, no qual foram excluídos o RMS, o SSC e o WA. Na Tabela 5.12 é possível que observar que os resultados foram inferiores com relação aos treinamentos dos demais grupos. O melhor resultado foi quando o LM foi treinado com 15 neurônios e 1000 épocas, onde se obteve 79,4% de acurácia. O pior desempenho foi quando o treino com o classificador

Rprop foi configurado com 5 neurônios e 500 épocas, obtendo um resultado de 72,9%.

Tabela 5.12 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem as características RMS, SSC e WA.

Grupo	NH	Época	Rprop				LM			
			Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]	Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]
G11	5	500	2,97	86,7	72,9	80,8 / 2	25,26	86,4	74,4	85,2 / 1
	10		3,19	87,9	77,5	88,4 / 2	68,93	87,3	78,6	87,6 / 2
	15		3,38	88,8	79,1	91,6 / 2	142,89	87,8	77,8	90,0 / 2
	5	1000	4,35	87,7	76,9	88,0 / 2	49,25	86,3	74,3	86,0 / 2
	10		4,77	87,8	78,5	86,0 / 2	128,19	88,2	79,0	87,6 / 1
	15		5,20	88,1	78,6	88,8 / 2	311,66	88,0	79,4	86,8 / 2


Fonte: Autoria própria.

Devido a expressividade do baixo resultado com este grupo de atributos, serão apresentadas as matrizes e as curvas ROC do melhor e do pior resultado encontrado. A comparação das matrizes, considerando o melhor valor encontrado com o G11, é apresentada na Figura 5.21, onde podem ser vistos os resultados pouco satisfatório, tanto de TVP, quanto de precisão de cada classe. A Classe 4, na matriz do Rprop, apresenta a pior precisão, apenas 66%. Já a Classe 2, com os dois classificadores, é apontada como a melhor.

Nas curvas ROC da Figura 5.22, pode-se perceber que, quando observado o gráfico do RP, a Classe 4 possui taxa de falso positivo elevada, mas depois melhora e a Classe 3 é a que aparece com o resultado mais baixo de taxa de verdadeiro positivo. Já no LM, a Classe 4 se apresenta com a pior taxa de verdadeiro positivo e a com valores mais elevados de falso positivo.


Os resultados das matrizes de confusão e curvas ROC dos classificadores com o pior desempenho do G11, estão representados nas Figura 5.23 e Figura 5.24 respectivamente. Na matriz com o classificador Rprop é possível verificar os baixos resultados, chamando a atenção para as Classes 3 e 4 com relação à TVP e para as Classes 4 e 5 com relação à precisão. No LM, a precisão da Classe 4 foi expressivamente menor, com apenas 58%. E a taxa de verdadeiro positivo da classe 5 obteve o pior resultado, apenas 63,6%. As curvas ROC de ambos classificadores mostram que a Classe 3 obteve a menor área do gráfico, logo, o pior resultado.

Figura 5.21 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem as características RMS, SSC e WA – 5 NH – 500 épocas.




Fonte: Autoria própria.

Figura 5.22 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem as características RMS, SSC e WA – 5 NH – 500 épocas.




Fonte: Autoria própria.

Figura 5.23 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem as características RMS, SSC e WA – 5 NH – 500 épocas.



Fonte: Autoria própria

Figura 5.24 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem as características RMS, SSC e WA – 5 NH – 500 épocas.



Fonte: Autoria própria.

Por fim, o Grupo 12, no qual é formado por 5 atributos, uma vez que o RMS, o WL e o ZC foram retirados. Os resultados podem ser visualizados na Tabela 5.13, onde o melhor resultado obtido foi com o Rprop quando configurado com 10 neurônios e 500 épocas de treinamento, resultando em 81,8% de acurácia. O pior resultado foi encontrado com o classificador LM com a mesma configuração. E a Classe 2 se destacou com 95,2% de eficiência.

A Figura 5.25 apresenta as matrizes de confusão deste grupo quando o treinamento é realizado com 10 neurônios e 500 épocas, representando, coincidentemente, o melhor e o pior resultado do G12, uma vez que o Rprop alcançou uma acurácia de 81,8% e, o LM de 70,3%. As Classes 3, 4 e 5 apresentaram precisões com valores próximos com os dois classificadores. A Classe 2 teve o melhor desempenho em ambos, sendo muito expressivo com o Rprop.


As curvas ROC apresentadas na Figura 5.26 corroboram os resultados encontrados no melhor caso deste agrupamento, que foi na utilização de 10 neurônios e 500 épocas com o RP. Ainda assim, verifica-se uma perda de eficiência considerável no caso do LM apresentando uma linearidade com relação à taxa de verdadeiro positivo.

Tabela 5.13 – Resultados comparativos entre os algoritmos Rprop e LM para o conjunto sem as características RMS, WL e ZC.

Grupo	NH	Época	Rprop				LM			
			Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]	Tempo Médio [min]	PE [%]	Acurácia [%]	Melhor Classe [%/n°]
G12	5	500	3,21	87,8	76,5	92,4 / 2	25,56	87,2	77,2	86,8 / 1
	10		3,25	88,8	81,8	95,2 / 2	71,91	87,7	70,3	90,0 / 2
	15		3,53	89,3	81,4	92,8 / 2	155,04	88,0	79,4	88,4 / 2
	5	1000	4,45	87,8	76,9	86,8 / 2	49,85	87,0	78,1	86,4 / 2
	10		4,86	88,9	79,1	88,8 / 2	142,53	88,2	78,2	87,2 / 2
	15		5,41	88,9	81,1	89,2 / 2	308,15	87,8	78,6	85,6 / 2


Fonte: Autoria própria.

Figura 5.25 – Matrizes de confusão das comparações obtidas com os algoritmos Rprop e LM para o conjunto sem as características RMS, WL e ZC – 10 NH – 500 épocas.



Fonte: Autoria própria.

Figura 5.26 – Curva ROC: comparação entre os algoritmos Rprop e LM para o conjunto sem as características RMS, WL e ZC – 10 NH – 500 épocas: melhor resultado.



Fonte: Autoria própria.

5.1 Análise dos Resultados

Foram realizados um total de 144 testes, sendo metade destes para cada algoritmo trabalhado nesta pesquisa, *Resilient Backpropagation* e *Levenberg-Marquardt*. Para a obtenção desse valor, foram realizadas de forma arbitrária combinações entre as características, formando 12 grupos (1- Todas as características, 2- exceto MAV, 3- excluindo-se RMS, 4- retirando-se VAR, 5- exceto

WL, 6- excluindo-se ZC, 7- retirando-se SSC, 8- exceto WA e SSC, 9- retirando-se WL e SSC, 10- exceto WL e WA, 11- sem RMS, SSC e WA e 12- sem RMS, WL e ZC), variando-se o número de neurônios, ou seja, todos os conjuntos foram testados com 5, 10 e 15 neurônios na camada oculta e, além disso, alterando a quantidade de épocas, utilizando 500 e 1000 épocas, na tentativa do melhor desempenho e na verificação de quais atributos são os mais relevantes entre os sete visto no Capítulo 4.

A Tabela 5.14 traz resumidamente a comparação entre o melhor e o pior desempenho dos classificadores por grupo. O método *Levenberg-Marquardt* apresentou melhor desempenho em 7 dos 12 grupos, porém com uma diferença de acurácia pouco expressiva com relação aos resultados obtidos com o *Resilient Backpropagation*, portanto, no geral, O RBP pode ser considerado melhor para esse tipo de situação.

Tabela 5.14 – Resumo entre o melhor e o pior desempenho por grupo.

Grupos	Melhor Desempenho			Pior Desempenho		
	Rprop	LM	Classe	Rprop	LM	Classe
G1	82,4	82,6	2	78,6	77,7	4
G2	81,5	81,7	2	76,7	75,4	4
G3	81,0	79,6	2	76,8	76,2	4
G4	81,4	82,3	2	77,4	75,5	4
G5	80,5	81,4	2	77,8	74,9	4
G6	88,2	88,4	1	84,5	83,4	4
G7	82,6	82,5	2	78,1	74,6	4
G8	85,0	83,4	2	78,4	75,4	4
G9	82,3	81,5	2	76,6	78,2	4
G10	81,9	82,2	2	77,3	76,7	4
G11	79,1	79,4	2	72,9	74,3	4
G12	81,8	79,4	2	76,5	70,3	4

Fonte: Autoria própria.

O resultado entre todos os 144 testes, com a melhor acurácia da matriz de confusão, que pode ser melhor vista na Tabela 5.14 e, foi o Grupo 6, sem o atributo ZC, com 15 neurônios e 1000 épocas, obtendo-se 88,2% de acurácia global com o algoritmo Rprop e 88,4% com o LM e 100% de acerto para a Classe 1 em ambos os casos.

O resultado com menor desempenho geral foi com o Grupo 11, no qual se excluiu o RMS, SSC e WA, encontrando-se como valor mais baixo 72,9% de acurácia com o

Rprop, atingindo o máximo de 79,4% de acurácia com o LM. Ainda neste grupo, encontrou-se a taxa de verdadeiro positivo mais baixa (Figura 5.27), principalmente devido ao fato de a Classe 4 ter sido confundida com a Classe 5 em 57 amostras.

Figura 5.27 – Matriz de confusão do conjunto sem RMS, SSC e WA – 15NH – 500 épocas.

Matriz de Confusão

Classe de Saída	1	203 16,2%	10 0,8%	13 1,0%	4 0,3%	0 0,0%	88,3% 11,7%
	2	18 1,4%	229 18,3%	4 0,3%	1 0,1%	1 0,1%	90,5% 9,5%
	3	19 1,5%	7 0,6%	201 16,1%	31 2,5%	8 0,6%	75,6% 24,4%
	4	5 0,4%	2 0,2%	27 2,2%	157 12,6%	42 3,4%	67,4% 32,6%
	5	5 0,4%	2 0,2%	5 0,4%	57 4,6%	199 15,9%	74,3% 25,7%
			81,2% 18,8%	91,6% 8,4%	80,4% 19,6%	62,8% 37,2%	79,6% 20,4%
		1	2	3	4	5	
		Classe Alvo					

Fonte: Autoria própria.

Porém, conforme a Tabela 5.14 o pior resultado foi encontrando no Grupo 12, pontualmente, no classificador LM com acurácia de 70,3%. Os resultados dos Grupos 5, 9 e 10 (retirada do WL em comum) possuem valores muito próximos, sugerindo que o SSC e o WA não possuem muita influência no treinamento. Pode-se verificar também, que nos Grupos 3, 11 e 12, nos quais o atributo RMS é retirado, obteve-se os piores resultados, uma vez que esse atributo funciona como uma técnica de avaliação do nível de atividade do sinal.

Capítulo 6

6. CONCLUSÕES

Conforme verificado, inseridos propositalmente, as Classes 3, 4 e 5 possuem grupos de ativação bem similares, sendo a principal diferença entre eles, a amplitude do sinal, justificando-se a quantidade de erros entre essas três Classes. Porém, mesmo com esse obstáculo a Rede Neural Artificial se mostrou eficaz.

Foi visto no capítulo anterior o desempenho dos treinamentos e a comparação entre os dois classificadores. Pôde-se perceber o quão significativo o atributo RMS é para a eficácia da rede, tanto que os grupos com desempenho mais baixo foram os que este atributo foi excluído, Grupos 3, 11 e 12.

O melhor resultado encontrado foi com o Grupo 6, onde a característica ZC foi excluída, resultando em uma acurácia de 88,4% com o LM e 88,2% com o Rprop, diferença pouco significativa para um tempo de processamento muito mais elevado, logo *Resilient Backpropagation* se mostra a melhor solução.

Outro ponto positivo e surpreendente para o método realizado foi o fato de mesmo realizando testes com pessoas diferentes, em dias diferentes – o que ocasiona a retirada da braçadeira e a sua posterior recolocação, podendo os eletrodos estarem posicionados de forma pouco precisa (com certa diferença do dia anterior), a rede obteve bom desempenho.

Em publicações anteriores foi verificado que a retirada do atributo WL para os treinos fornece os melhores resultados para treinos de 4 Classes (FONSECA, 2017 e 2018), a partir do momento que uma Classe foi adicionada, novos conjuntos de características foram gerenciados na procura do melhor classificador neural, outro resultado foi obtido e, neste caso, o melhor resultado obtido foi na retirada do ZC

Outra vantagem dessa classificação utilizando RNA é que diferentemente do processo padrão do Myo®, dispensa-se o processo de calibração do usuário, trazendo facilidade e comodidade ao usuário final no comando do dispositivo desejado.

Mesmo com o uso da interface padrão do Myo® realizando a calibração para os gestos pré-programados dele, não se obtém 100% de acurácia, ou seja, mesmo com todo o processo convencional e calibração da braçadeira, a mesma ainda apresenta alguns erros, como o não reconhecimento do gesto ou a classificação errada. Logo o

resultado obtido com gestos diferentes e sem calibração com os classificadores apontados pode ser considerado satisfatório.

6.1 Trabalhos Futuros

Como possíveis temas de trabalho para continuar essa pesquisa pode-se mencionar:

- Criação de um algoritmo para o reconhecimento de mais gestos da mão e desenvolvimento de uma interface homem-máquina fazendo que os gestos executados sejam programados para a realização de controle de dispositivos, inclusive próteses robóticas;
- Utilização de Redes Neurais Artificiais para identificar se o paciente está executando o movimento de forma correta ao praticar exercícios de reabilitação;
- Uso do sinal EMG para detecção de fadiga muscular;
- Uso do sinal EMG para auxiliar profissionais de reabilitação (ex: fisioterapeutas) a acompanharem a evolução dos pacientes.

REFERÊNCIAS

- ABDUO, M.; GALSTER, M. **Myo Gesture Control Armband for Medical Applications**. Department of Computer Science and Software Engineering - University of Canterbury, 2015.
- AGUR, A. M. R.; DALLEY, A.F. **Grant Atlas de Anatomia**. Rio de Janeiro: Editora Guanabara Koogan, ed. 11, 2006.
- AHSAN, R.; IBRAHIMY, M. I e KHALIFA, O. O. **Electromyography (EMG) signal based hand gesture recognition using Artificial Neural Network (ANN)**. 4th International Conference on Mechatronics, Malasia, p. 17-19, 2011.
- ALBRECHT, B. L. **Controle de uma Cadeira de Rodas Motorizada através de Eletromiografia em uma Plataforma Embarcada**. Trabalho de conclusão do curso de Engenharia da Computação, Universidade Federal do Rio Grande do Sul, Porto Alegre – RS, 2010.
- ALMEIDA, T. P. **Decomposição de Sinais Eletromiográficos de Superfície Misturados Linearmente Utilizando Análise de Componentes Independentes**. Dissertação de Mestrado, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas – SP, 2012.
- AL-SULTANI, Z. N. A. **An Enhanced Resilient Backpropagation Artificial Neural Network for Intrusion Detection System**. Dissertação de Mestrado - Faculty of Information Technology, Middle East University, Amman – Jordan, 2012.
- ANASTASIADIS, A. D. **Neural Networks Training and Applications using Biological Data**. Tese de Doutorado - University of London, London, 2005.
- ANDRADE, A. O. **Metodologia para Classificação de Sinais EMG no Controle de Membros Artificiais**. Dissertação de Mestrado em Engenharia Elétrica apresentada à Universidade Federal de Uberlândia, 2000.
- ARIEF, Z. et al. **Comparison of Five Time Series EMG Features Extractions Using Myo Armband**. Escola de Engenharia, Politeknik Elektronika Negeri Surabaya, Indonesia, p 11-14, 2015.
- ATZORI, M. et al. **Deep Learning with Convolutional Neural Networks Applied to Eletromiography Data: A Resouce for the Classification of Movements for**

Prosthetic Hands. *Frontiers in Neurorobotics*, v. 10, 2016. Disponível em: <https://www.frontiersin.org/articles/10.3389/fnbot.2016.00009/full>. Acesso em: 15 jan. 2019.

AVAN et al. **Comparison of Backpropagation and Resilient Backpropagation Algorithms in Non-Invasive Blood Glucose Measuring Device.** *International Journal of Scientific & Engineering Research*, v. 8, issue 8, 2017.

AZEVEDO, Samuel, et al. Minicurso: **Introdução a Robótica Educacional.** Disponível em: <http://www.uesb.br/mat/semat/seemat2/index_arquivos/mc5.pdf>. Acesso em: 15 nov 2015.

BARRETO, J. M. **Introdução às Redes Neurais Artificiais.** Laboratório de Conexionismo e Ciências Cognitivas da Universidade Federal de Santa Catarina, Florianópolis – SC, 2002.

BERNARDES, W. M. S. et al. **Decomposição e análise de sinais Eletromiográficos.** V Conferência de Estudos em Engenharia Elétrica, Universidade Federal de Uberlândia – MG, 2007.

BERSCH, Rita. **Introdução à Tecnologia Assistiva.** Porto Alegre: Assistiva, Tecnologia e Educação, 2013. Disponível em: <http://www.assistiva.com.br/Introducao_Tecnologia_Assistiva.pdf>. Acesso em: 28 fev. 2014.

BITTENCOURT, G. **Conexionismo.** Florianópolis: Departamento de Automação e Sistemas da Universidade Federal de Santa Catarina. Disponível em: https://intranet.dcc.ufba.br/pastas/mecateam/material_de_estudo/ia/iaconexionista/conex.pdf. Acesso em: 10 ago. 2016.

BRASIL. **Cartilha do Censo 2010: Pessoas com Deficiência.** Secretaria de Direitos Humanos da Presidência da República – SDH/PR, Secretaria Nacional de Promoção dos Direitos da Pessoa com Deficiência – SNPD e Coordenação -Geral do Sistema de Informação sobre a Pessoa com Deficiência, 2012. Disponível em: <http://www.pessoacomdeficiencia.gov.br>. Acesso em 10 ago. 2016.

BRASIL. **Decreto nº 3.298, de 20 de Dezembro de 1999.** Disponível em: <http://www.planalto.gov.br/ccivil_03/decreto/d3298.htm>. Acesso em: 9 mar. 2014.

BRASIL. **Decreto nº 5.296, de 2 de Dezembro de 2004.** Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2004/decreto/d5296.htm>.

Acesso em: 9 mar. 2014.

BRASIL. **Pessoas com deficiência.** Subsecretaria Nacional de Promoção dos Direitos da Pessoa com Deficiência. Comitê de Ajudas Técnicas. Tecnologia Assistiva. Brasília: CORDE, 2009. Disponível em: <<http://www.pessoacomdeficiencia.gov.br/app/sites/default/files/publicacoes/livro-tecnologia-assistiva.pdf>>. Acesso em: 28 fev. 2014.

CARVALHO, A.; LUDEMIR, A. **Fundamentos de Redes Neurais Artificiais.** 11ª Escola de Computação. Imprinta Gráfica e Editora Ltda, 1998.

CLANCY, E. A. et al. **Sampling, noise-reduction and amplitude estimation issues in surface electromyography.** Journal of Electromyography and Kinesiology 12, p. 1-16, 2002.

Clínica de Desenvolvimento. Disponível em: <http://www.clinicadesenvolvimento.com.br/novo/tratamentos/Orteses-e-Tecnologia-Assistiva>-<http://--clinicadesenvolvimentohumano.blogspot.com.br-/16/>. Acesso em: 04 set. 2018.

CRUZ, F. C. **Seleção Eficiente de Características para um Sistema de apoio à Decisão Baseado em redes Neurais Aplicado a Inspeções não Destrutivas por Ultrassom.** Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal da Bahia, 2014.

DE LUCA, C. J. et al. **Decomposition of Surface EMG Signals.** Journal of Neurophysiology, v. 96, p. 1646-1657, 2006.

DE LUCA, C. J. **Surface Electromyography: Detection and Recording.** DelSys Incorporated, 2002.

DE LUCA, C. J. **The use of surface electromyography in biomechanics.** Journal of applied biomechanics, p 135-163, 1997.

DE LUCA, J. C. et al. **Filtering the Surface EMG Signal: Movement Artifact and Baseline Noise Contamination.** Elsevier Journal of Biomechanics, Boston – Estados Unidos da América, p. 1573-1579, 2010.

DIAS, F. M. et al. **Implementing the Levenberg-Marquardt Algorithm On-Line: a Sliding Window Approach with Early Stopping**. Escola Superior de Tecnologia de Setúbal do Instituto Politécnico de Setúbal, Departamento de Engenharia Eletrotécnica, Campus IPS, Estefanilha, Setúbal – Portugal, v.37, issue 16, p. 49-54, 2004.

Educadores. **Tecnologia no contexto escolar**. Anexo 3 Tecnologia Assistiva para o acesso e a participação de estudantes com deficiência no contexto escolar. Secretaria de Educação do Governo do Estado do Paraná. Disponível em: http://www.educadores.diaadia.pr.gov.br/arquivos/File/formacao_acao/1semestre_2015/tecnologia_anexo3.pdf. Acesso em: 04 set. 2018.

ELAMVAZUTHI, I. et al. **Electromyography (EMG) based Classification of Neuromuscular Disorders using Multi-Layer Perceptron**. 2015 IEEE International Symposium on Robotics and Intelligent Sensors – IRIS 2015, Langkawi – Malaysia, p. 223-228, 2015. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1877050915038478>. Acesso em: 15 jan. 2019.

FAVIEIRO, G. W. **Controle de uma Prótese Experimental do Segmento Mão-Braço por Sinais Mielétricos e Redes Neurais Artificiais**. Trabalho de conclusão do curso de Engenharia da Computação, Universidade Federal do Rio Grande do Sul, Porto Alegre – RS, 2009.

FAWCETT, T. **An introduction to ROC analysis**. Pattern Recognition Letters 27, v. 27, p. 861-874, 2006.

FONSECA, M. G. B. et al. **Artificial Neural Networks Applied the Classification of Hand Gesture Using Electromyographic Signals**. 14th Latin American Robotics Symposium – LARS, Curitiba – Paraná, 2017.

FONSECA, M. G. B. et al. **Classificador de gestos por Redes Neurais Artificiais utilizando Sinais Mielétricos**. XXXVI Simpósio Brasileiro de Telecomunicações e Processamento de Sinais -SBrT2018, Campina Grande – Paraíba, 2018.

FRERIKS, B. et al. **SENIAM 1: European Activies on Surface Electromyography**. Proceedings of the First General SENIAM Workshop, Alemanha, p. 361-374, 1996.

GANIEV, A. et al. **Study on Virtual Control of Robotic Arm via a Myo Armband for the self-manipulation of a hand amputee**. Índia: International Journal of Applied Engineering Research, v. 11, n.2, p. 775-782, 2016. Disponível em: <http://www.ripublication.com>. Acesso em: 01 ago 2016.

Geotrilhas. Disponível em: <http://www.geotrilhas.blogspot.com/2012/06/faltam-rampas-de-acesso-nas.html>. Acesso em: 04 set. 2018.

GONDRAN, C. et al. **Noise of Surface Bio-potential Electrodes Based on NASICON Ceramic and Ag-AgCl**. Laboratoire d'Ionique et d'Electrochimie du Solide de Grenoble, França, p. 460-466, 1996.

HAGAN, M. T.; MENHAJ, M. B. **Training Feedforward Networks with the Marquardt Algorithm**. IEEE Transaction on Neural Networks, v.5, no.6, p. 989-993, 1994.

HASSAN, H. F. et al. **Teleoperated Robotic Arm Movement Using EMG Signal with Wearable MYO Armband**. Departamento de Engenharia Eletrica, Universidade de Bagdad, Al-Jadriyah, 2016.

HAYKIN, S. **Neural Networks: Principles and Practice**. McMaster University, Ontário, Canadá, 2001.

HUIGEN, E. et al. **Investigation into the origin of the noise of surface electrodes**. Medical & Biological Engineering & Computing, v. 40, p. 332-338, 2002.

Inovação Tecnológica. Disponível em: https://www.inovacaotecnologica.com.br/noticias/noticia.php?artigo=uma-olimpiada-tecnologias-assistivas-roboticas&id=010180160218#.W_eG7ThKjIU. Acesso em: 04 set. 2018.

JAIN, A.K. et al. **Statistical pattern recognition: a review**. IEEE Trans. Pattern Analysis, v. 22, n.1, p. 4-37, 2000.

Kandel. Disponível em: <https://kandel.com.br/eletrodos/emg/ambu-neuroline-715/>. Acesso em: 02 nov. 2018.

KARLSSON, J. et al. **Signal processing of the surface electromyogram to gain insight into neuromuscular physiology**. The Royal Society Journal, p. 337-356, 2008.

KASABOV, N. K. **Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering**. The MIT Press, A Bradford Book, 1996.

KISI, Ö.; UNCUOGLU, E. **Comparison of three back-propagation training algorithms for two case studies**. Indian Journal of Engineering & Materials Sciences, v. 12, p 434-442, 2005.

KORDOS, M. **Search-based Algorithms for Multilayer Perceptrons**. Tese de Doutorado - The Silesian University of Technology, Gliwice, 2005.

LEAL, H.; SAIKUSA, C., 2013. Disponível em: <http://fisioterapiahumberto.blogspot.com/2013/01/fisioterapia-pos-fratura-de-colles.html>. Acesso em: 01 dez. 2018.

LOEB, G. E.; GHEZ, C. **The Motor Unit and Muscle Action**. Principles of Neural Science, ed. 4, McGraw-Hill Companies, 2000.

MANE, S. M. et al. **Hand Motion Recognition from Single Channel Surface EMG using Wavelet & Artificial Neural Network**. 4th International Conference on Advances in Computing, Communication and Control – ICAC3'15, Mumbai - Índia, p. 58-65, 2015.

MARIEB, E. N.; HOEHN, K. **Human Anatomy & Physiology**. Benjamin Cummings Publishing Company Inc. 7 ed. San Francisco, Estados Unidos da América, 2006.

MERLETTI, R. et al. **Technology and instrumentation for detection and conditioning of the surface electromyographic signal: State of the art**. Elsevier, Clinical Biomechanics, p. 122-134, 2009.

MeSH - Medical Subject Headings. Disponível em: <https://www.nlm.nih.gov/mesh/>. Acesso em: 25 jul. 2016.

Myo armband. Disponível em: <https://www.myo.com>. Acesso em: 01 mar. 2016.

NAGEL, J. H. **Biopotential Amplifiers**. Biomedical Engineering Handbook. Ed.2, CRC Press LLC, 2000.

ORTOLAN, R. L. **Estudo e Avaliação de Técnicas de Processamento do Sinal Mioelétrico para o Controle de Sistemas de Reabilitação**. Dissertação de Mestrado em Engenharia Elétrica apresentada à Escola de Engenharia de São Carlos, São Carlos – SP, 2002.

PATEL, K.; PATEL, P. **Analysis of Feature Training Set for Improving Classification Accuracy**. International Research Journal of Engineering and Technology, v.3, Dept. of Biomedical engineering, Government Engineering College, Gandhinagar, Gujarat, India, p. 2085-2090, 2016.

PHINYOMARK, A. et al. **Feature Extraction and Selection for Myoelectric Control Based on Wearable EMG Sensors**. MDPI, 2018. Disponível em: <http://www.mdpi.com/journal/sensors>. Acesso em: 02 set. 2018.

PHINYOMARK, A. et al. **Feature reduction and selection for EMG signal classification**. Department of Electrical Engineering, Faculty of Engineering – Prince of Songkla University, Thailand, 2012.

PORTUGAL. **Catálogo Nacional de Ajudas Técnicas**. Disponível em: <http://www.ajudastecnicas.gov.pt/about.jsp>. Acesso em: 9 mar. 2014.

POZZO, M. et al. **Eletromiography: Detection, Processing and Applications. Biomedical Technology and Devices Handbook**. Edited by James moore and George Zouridakis, CRC Press.

PRINDLE, D. **Myo gesture control armband review**. Digital Trends, 2015. Disponível em: <http://www.digitaltrends.com/pc-accessory-reviews/myo-gesture-control-armband-review/#/7>. Acesso em: 04 mar. 2016.

QUEVEDO, A. A. F. **Desenvolvimento de um Sistema de Análise Digital de Sinais EMG**. Dissertação de Mestrado apresentada à Faculdade de Engenharia Elétrica e da Computação, Universidade Estadual de Campinas – UNICAMP, Campinas – SP, 1993.

SAMPAIO, A. C. **Eletromiógrafo de Doze Canais para Uso em Laboratório de Pesquisa**. Dissertação de Mestrado apresentada à Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas – SP, 1998.

SOUZA, E. E. P. **Pré-Processamento Eficiente para um Sistema Online de Classificação Baseado em Redes Neurais Artificiais**. Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal da Bahia, 2015.

- SOUZA, L. R. **Algoritmo para Reconhecimento e Acompanhamento de Trajetórias de Padrões em Vídeos**. Trabalho de conclusão de curso, Engenharia da computação, Universidade Federal do Vale do São Francisco, Juazeiro – BA, 2011.
- STEVENS, T.; LOVRIC, D. **Artificial Neural Networks - In data pattern recognition for monitoring purpose**. Trabalho de conclusão de graduação - Lund University, Helsingborg- Suécia, 2011.
- SUBASI, A. et al. **Classification of EMG signals using wavelet neural network**. Journal of Neuroscience Methods, vol. 156, p. 360-367, 2006.
- TISSOT, H. C.; CAMARGO, L. C. e POZO, A. T. R. **Treinamento de Redes Neurais Feedforward: comparativo dos algoritmos Backpropagation e Differential Evolution**. Departamento da Computação da Universidade Federal de Curitiba, Curitiba – PR, 2012.
- ZAMBIASI, S. P. **Introdução às Redes Neurais Artificiais**. Dissertação de Mestrado apresentada a Universidade Federal de Santa Catarina, Florianópolis – SC, 2002. Disponível em: <http://www.gsigma.ufsc.br>. Acesso em 20 nov. 2016.

APÊNDICE A

Trabalhos Publicados

Seguem abaixo os resumos dos trabalhos científicos publicados com os resultados encontrados da pesquisa, que fundamentou esta dissertação.

A-1 Artigos em Congressos

1. Michelle Burgos, André Scolari e Eduardo Simas. Artificial Neural Networks applied to the classification of hand gestures using Eletromyographic Signals. 14rd Latin American Robotics Symposium. Curitiba-PR, Novembro de 2017.

Resumo:

Neste artigo foi proposta a classificação de gestos de mão usando sinais eletromiográficos (EMG) obtidos através de uma braçadeira Myo, que possui oito eletrodos de grau médico. Cada eletrodo fornece informações sobre a contração muscular realizada durante a execução do movimento. A partir desses sinais foram extraídas seis características dos oito eletrodos em cada teste. Uma Rede Neural Artificial de duas camadas foi usada para classificação automática. A motivação desta pesquisa foi o reconhecimento de gestos para a interação homem-robô. Os resultados experimentais são apresentados para demonstrar o desempenho do método proposto.

2. Michelle Burgos, Edmar Egídio, André Scolari e Eduardo Simas. Classificador de Gestos por Redes Neurais Artificiais utilizando Sinais Mioelétricos. XXXIV Simposio Brasileiro de Telecomunicações e Processamentos de Sinais. Campina Grande-PB, Setembro de 2018.

Resumo:

Neste trabalho é apresentado um sistema de classificação, baseado em Redes Neurais Artificiais, para discriminação de gestos de mão utilizando sinais eletromiográficos (EMG), que são obtidos através de uma braçadeira Myo composta por oito eletrodos que realizam a aquisição da informação da contração muscular durante a execução de movimentos padrões. É realizado um pré-processamento nos sinais adquiridos, extraindo sete características para cada eletrodo. Visando analisar o melhor desempenho do classificador, dois algoritmos de treinamento foram

utilizados, o *Resilient Backpropagation* (Rprop) e *Levenberg Maguard* (LM), onde o algoritmo Rprop, obteve cerca de 91,3% de acerto de classificação das quatro classes de movimentos estudados, em relação ao algoritmo LM. Os resultados experimentais são apresentados para validar o método proposto.