

Universidade de Brasília - UnB

Faculdade UnB Gama - FGA

Engenharia Eletrônica

**CLASSIFICAÇÃO DE GESTOS DAS MÃOS  
USANDO PLATAFORMAS VESTÍVEIS  
BASEADAS EM ELETROMIOGRAFIA DE  
SUPERFÍCIE NO ANTEBRAÇO E UNIDADES  
INERCIAIS**

Autor: Paulo Henrique Gomes Machado

Orientador: Prof. Dr. Marcus Vinícius Chaffim Costa

Coorientador: Prof. Me. Mateus Mendelson Esteves da Silva

Brasília, DF

2018





Paulo Henrique Gomes Machado

**CLASSIFICAÇÃO DE GESTOS DAS MÃOS USANDO  
PLATAFORMAS VESTÍVEIS BASEADAS EM  
ELETROMIOGRAFIA DE SUPERFÍCIE NO  
ANTEBRAÇO E UNIDADES INERCIAIS**

Monografia submetida ao curso de graduação em Engenharia Eletrônica da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em Engenharia Eletrônica.

Universidade de Brasília - UnB

Faculdade UnB Gama - FGA

Orientador: Prof. Dr. Marcus Vinícius Chaffim Costa

Coorientador: Prof. Me. Mateus Mendelson Esteves da Silva

Brasília, DF

2018

---

Paulo Henrique Gomes Machado

CLASSIFICAÇÃO DE GESTOS DAS MÃOS USANDO PLATAFORMAS VESTÍVEIS BASEADAS EM ELETROMIOGRAFIA DE SUPERFÍCIE NO ANTEBRAÇO E UNIDADES INERCIAIS/ Paulo Henrique Gomes Machado. – Brasília, DF, 2018-

90 p. : il. 30 cm.

Orientador: Prof. Dr. Marcus Vinícius Chaffim Costa

Trabalho de Conclusão de Curso – Universidade de Brasília - UnB  
Faculdade UnB Gama - FGA , 2018.

1. Eletromiografia. 2. Processamento de sinais. I. Prof. Dr. Marcus Vinícius Chaffim Costa. II. Universidade de Brasília. III. Faculdade UnB Gama. IV. CLASSIFICAÇÃO DE GESTOS DAS MÃOS USANDO PLATAFORMAS VESTÍVEIS BASEADAS EM ELETROMIOGRAFIA DE SUPERFÍCIE NO ANTEBRAÇO E UNIDADES INERCIAIS

CDU 02:141:005.6

---

Paulo Henrique Gomes Machado

# **CLASSIFICAÇÃO DE GESTOS DAS MÃOS USANDO PLATAFORMAS VESTÍVEIS BASEADAS EM ELETROMIOGRAFIA DE SUPERFÍCIE NO ANTEBRAÇO E UNIDADES INERCIAIS**

Monografia submetida ao curso de graduação em Engenharia Eletrônica da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em Engenharia Eletrônica.

Trabalho aprovado. Brasília, DF, 09 de Julho de 2018:

---

**Prof. Dr. Marcus Vinícius Chaffim  
Costa**  
(Orientador)

---

**Prof. Me. Mateus Mendelson Esteves  
da Silva**  
(Coorientador)

---

**Prof. Dr. Cristiano Jacques Miosso**  
(Examinador Interno)

---

**Prof. Dr. Alexandre Zaghetto**  
(Examinador Interno)

Brasília, DF  
2018



*À Val e José.*





# Agradecimentos

Agradeço primeiramente a Deus que me concedeu esse sonho de ser engenheiro e que em breve se realizará, também agradeço a minha família por todo suporte dado, em tempo e fora de tempo, por não me deixar desanimar e por me incentivar a ser e fazer o melhor sempre.

À minha amada namorada Camila Dantas por toda paciência durante os árduos anos de dedicação ao curso e aos meus amigos que sempre estão por perto quando há espaço para boas risadas.

Agradeço os professores que tive aulas, desde o começo, ainda calouro, até os mais recentes nas matérias finais de engenharia. Agradecimento especial aos que mais me motivaram a ser um profissional melhor: Prof. Dr. Cristiano Jacques e Profa. Dra. Suélia Rodrigues. Agradeço o Prof. Dr. Marcus Chaffim, que me acolheu como aluno de TCC, mesmo sem me conhecer muito e sempre me ajudou nos momentos mais complicados. Meu agradecimento também ao Prof. Me. Mateus Mendelson pelas muitas ajudas e reuniões.

Aos meus amigos de curso, que tornaram a caminhada mais descontraída: Lucas Delfino, Karine Ribeiro, Luciana Alves, Murilo Venturin, Flávia Leite, Lívia Santana, Jucelino Brito, Mônica Damasceno, Luiza Irina, entre outros que não posso listar mas que foram essenciais.



*“Porque, se vivemos, para o Senhor vivemos;  
se morremos, para o Senhor morremos.  
Quer, pois, vivamos ou morramos, somos do Senhor.  
(Bíblia Sagrada, Romanos 14, 8)*



# Resumo

Este trabalho propõe o estudo da eletromiografia de superfície (sEMG), com o auxílio de um bracelete disponível comercialmente, assim como a utilização de sensores inerciais magnetômetro, acelerômetro e giroscópio nele presentes para reconhecimento de movimentos realizados pela mão e pelo braço.

É objetivo do trabalho, primeiramente, obter os sinais de forma a ser possível gerar gráficos ao longo do tempo de aquisição, também se deseja coletar de maneira padronizada os sinais dos movimentos já reconhecidos pelo dispositivo Myo para formar uma base de dados estruturada, passível de melhorias. Além dos movimentos presentes no dispositivo na configuração do dispositivo, também é objetivo captar, formar uma base de dados e padronizar a forma de aquisição dos sinais de outros movimentos realizados pelas mãos e antebraço, movimentos estes escolhidos a partir da análise de movimentos de possível utilização para controle de alguma prótese mecânica, robô ou outro dispositivo de controle.

Os movimentos a serem classificados são os seguintes: mão fechada, mão aberta, mão à direita, mão à esquerda, duplo clique (polegar e dedo médio tocando-se duas vezes em curto intervalo de tempo), flexão do braço, extensão do braço, pronação do braço e supinação do braço.

Por fim, será abordada uma técnica de reconhecimento de padrões com uma rede neural artificial, na qual serão aplicados modelos computacionais para se obter a melhor taxa de acerto entre o que fora classificado pela rede e os alvos corretos. Entre as abordagens estão a utilização da extração de características de energia, potência, transformada wavelets e matriz de co-ocorrência de níveis de cinza (GLCM). Os resultados serão expressos em taxas de acerto da melhor rede e gráficos do melhor conjunto de validação para cada cenário proposto.

**Palavras-chaves:** processamento de sinais. eletromiografia. redes neurais artificiais. unidade de medidas inerciais.



# Abstract

This work proposes the study of Surface Electromyography (sEMG), in other words, non-invasive, with the aid of a commercially available device, as well as the use of its inertial sensors to recognize hand and arm movements. The device used is the Myo Armband, which has eight myoelectric electrodes that extend around the forearm, proportionally apart from one another. The device also contains an Inertial Measurement Unit (IMU) such as accelerometer, magnetometer and gyroscope. These sensors capture myoelectric signals and motions which are sent through Bluetooth to a computer.

Initially, this work aims at obtaining signals in a way that can be possible to generate graphs along the time of acquisition. It also aims at collecting motion data already recognized by the device in order to develop a structured data base liable to improvements. Therefore, a sequence of guidelines was generated in order to turn the data collection efficient and replicable. Besides the present movements already recognized by the device, it's also objective of this work to capture, develop a data base and standardize the procedures to acquire other hands and forearm movements, which were chosen after the analysis of possible movements used in controlling mechanical prosthesis, robot or other control devices.

The movements to be classified are the following: closed hand, open hand, hand to the right, hand to the left, double-click (thumb and middle finger double-clicking in a short period of time), arm flexion, arm extension, arm pronation and supination. These movements will be explained throughout the present work to a better understanding of the gesture itself and its relevance for the classification process.

Finally, a technique of patterns recognition will be used with an artificial neural network, in which will be applied computational models in order to obtain the best results within the target rate. The scenarios in which the data will be used are: only EMG data, EMG and IMU data, other classes of distinct signals. It will also be possible to obtain a comparative between different choices of neural network entrance characteristics, such as energy calculation and signal power, or even wavelet transform and application of the gray-level co-occurrence matrix (GLCM).

**Key-words:** signal processing. eletromyography. artificial neural network. inertial measurement unit.





# Lista de ilustrações

Figura 1 – Utilização do bracelete Myo para controle de uma prótese mecânica em pessoas que tiveram parte do braço amputado ou nasceram como má formação. . . . .	28
Figura 2 – Representação do movimento de remada no aparelho <i>2ROW</i> criado por alunos da UnB. O aparelho conta com uma estrutura de remo <i>indoor</i> , sistemas embarcados, unidade de medidas inerciais alocado na perna esquerda do atleta para avaliação do movimento realizado e visualização do movimento de remado no visor do aparelho. . . . .	29
Figura 3 – Drone contendo uma câmera sobrevoando uma cidade. O controle de um drone acontece remotamente por radiofrequência emitida de uma antena de um controle. . . . .	29
Figura 4 – Representação do potencial de ação na passagem de sódio, potássio e Cloro na camada muscular humana (BARBERO; MERLETTI; RAINOLDI, 2012) adaptado. . . . .	34
Figura 5 – Esquemático básico da representação de uma unidade motora e seus componentes, desde a ativação no córtex, passando pela medula espinal até cada unidade motora dos músculos (MERLETTI, 2004) adaptado. . . . .	35
Figura 6 – Geração do trem de impulsos (SORNMO; LAGUNA, 2015) adaptado. . . . .	36
Figura 7 – (a) Diversos trens de impulso sendo captados separadamente; (b) Sinal mioelétrico completo da aquisição em um músculo esquelético humano (SORNMO; LAGUNA, 2015) adaptado. . . . .	37
Figura 8 – Representação de uma unidade motora e do potencial de ação da unidade motora como elementos da eletrônica de funcionamento conhecido (FARINA; MERLETTI, 2016) adaptado. . . . .	38
Figura 9 – Representação do sistema de referência inercial utilizando um avião para demonstrar os movimentos. Roll é a rotação ao redor do eixo longitudinal, eixo X. Pitch é a rotação ao redor do eixo transversal, eixo Y. Yaw é o nome dado à rotação ao redor do eixo vertical, eixo Z (ROBOTICS, 2016) adaptado. . . . .	47
Figura 10 – Ilustração de identificação dos sensores do <i>Myo Armband</i> , o sensor número 4 tem um identificador luminoso para marcar o sensor de referência ao se colocar o bracelete no braço humano (SUNDSTROM, 2015) adaptado. . . . .	48
Figura 11 – Vista Inferior do <i>Myo Armband</i> utilizado durante as etapas de TCC 1 e TCC 2 do presente estudo. . . . .	49

Figura 12 – Modelo de neurônio artificial, existe um somatório de todas as entradas $x_1, x_2, \dots, x_n$ multiplicadas por um peso específico $w_1, w_2, \dots, w_n$ , sendo esse peso específico a relevância atribuída a cada entrada do neurônio, $\theta$ é o limiar de ativação, usado para especificar o limite apropriado na saída do somador, há ainda o $u$ , que desempenha o papel do potencial de ação que é o resultado produzido pela diferença entre o agregador de linear e do limite de ativação. O termo $g$ representa o valor final de saída de um neurônio, pode ser ainda representar a entrada na sequência para outro neurônio. (SILVA <i>et al.</i> , 2017) . . . . .	56
Figura 13 – Curva característica da tangente hiperbólica. O eixo das abscissas representa os valores $X$ de entrada na função $\tanh X$ e o eixo das ordenadas apresenta a resposta da função hiperbólica para cada entrada. . . . .	57
Figura 14 – Representação de uma rede neural multi-camadas contendo uma camada de entrada com 3 neurônios, 2 camadas ocultas contendo 4 neurônios cada e uma camada de saída com um neurônio somente.(JOHNSON, 2017) adaptado. . . . .	58
Figura 15 – Direções de referência adotadas no GLCM. . . . .	62
Figura 16 – Processo de construção de uma matriz GLCM a partir de uma imagem. A matriz de cima representa as intensidades nos níveis de cinza do sinal original, na debaixo é possível observar a matriz resultante após os cálculos de co-ocorrência dos níveis de cinza. . . . .	63
Figura 17 – Myo posicionado no braço direito . . . . .	68
Figura 18 – Gesto 1 ou mais especificamente: mão fechada, sendo realizado por um dos sujeitos. Vista lateral. . . . .	71
Figura 19 – Gesto 2 ou mais especificamente: mão aberta, sendo realizado por um dos sujeitos. Vista lateral. . . . .	71
Figura 20 – Gesto 3 ou mais especificamente: mão à direita, sendo realizado por um dos sujeitos. Vista superior. . . . .	72
Figura 21 – Gesto 4 ou mais especificamente: mão à esquerda, sendo realizado por um dos sujeitos. Vista superior. . . . .	72
Figura 22 – Gesto 5 ou mais especificamente: duplo clique (polegar e dedo médio tocando-se duas vezes em curto intervalo de tempo), sendo realizado por um dos sujeitos. Vista lateral. . . . .	72
Figura 23 – Gesto 6 ou mais especificamente: flexão do braço, sendo realizado por um dos sujeitos. Vista lateral. . . . .	73
Figura 24 – Gesto 7 ou mais especificamente: extensão do braço, sendo realizado por um dos sujeitos. Vista lateral. . . . .	73
Figura 25 – Gesto 8 ou mais especificamente: pronação do braço, sendo realizado por um dos sujeitos. Vista lateral. . . . .	73

Figura 26 – Gesto 9 ou mais especificamente: supinação do braço, sendo realizado por um dos sujeitos. Vista lateral. . . . .	73
Figura 27 – Captura de tela de um gráfico em tempo real com todos os sinais de EMG dos oito sensores presentes no bracelete Myo em um dos sujeitos em que o sinal fora coletado, no eixo das abscissas está o tempo de execução e na ordenadas os valores que cada um dos sinais atinge ao longo do tempo. . . . .	77
Figura 28 – Captura de tela de um gráfico em tempo real com os sinais separados, no eixo das abscissas está o tempo de execução e na ordenadas os valores que cada um dos sinais atinge ao longo do tempo. Cada um dos sinais se referem ao que fora captado no sensor do Myo de mesma numeração. . . . .	78
Figura 29 – Mapeamento dos padrões dos movimentos . . . . .	79
Figura 30 – Curvas de regressão para as etapas de treino, validação, teste e todas . . . . .	80
Figura 31 – Gráfico de evolução da rede neural. As linhas de melhor desempenho indicam o ponto em que o treinamento foi concluído. Neste ponto o erro do conjunto de validação é o menor sem que tenha vício. No eixo das ordenadas é possível ver o erro quadrático médio sobre o conjunto de dados de treino, validação e teste. No eixo das abscissas nota-se a quantidade de épocas durante a evolução da rede. . . . .	80
Figura 32 – Gráfico de evolução da rede neural do cenário 1. As linhas de melhor desempenho indicam o ponto em que o treinamento foi concluído. Neste ponto o erro do conjunto de validação é o menor sem que tenha vício. No eixo das ordenadas é possível ver o erro quadrático médio sobre o conjunto de dados de treino, validação e teste. No eixo das abscissas nota-se a quantidade de épocas durante a evolução da rede. . . . .	82
Figura 33 – Gráfico de evolução da rede neural do cenário 2. As linhas de melhor desempenho indicam o ponto em que o treinamento foi concluído. Neste ponto o erro do conjunto de validação é o menor sem que tenha vício. No eixo das ordenadas é possível ver o erro quadrático médio sobre o conjunto de dados de treino, validação e teste. No eixo das abscissas nota-se a quantidade de épocas durante a evolução da rede. . . . .	84
Figura 34 – Gráfico de evolução da rede neural do cenário 3. As linhas de melhor desempenho indicam o ponto em que o treinamento foi concluído. Neste ponto o erro do conjunto de validação é o menor sem que tenha vício. No eixo das ordenadas é possível ver o erro quadrático médio sobre o conjunto de dados de treino, validação e teste. No eixo das abscissas nota-se a quantidade de épocas durante a evolução da rede. . . . .	86



# Lista de tabelas

Tabela 1 – Aplicações típicas para acelerômetro e suas características desejáveis em cenários diferentes de atuação. A primeira coluna evidencia a aplicação, na segunda é possível observar a banda de atuação em que o acelerômetro tem funcionamento, a terceira coluna mostra a resolução do sensor, ou seja, a menor unidade de medida possível de leitura e a quarta coluna destaca o máximo de gravidade mensurável pelo sensor (BEEBY <i>et al.</i> , 2004). . . . .	42
Tabela 2 – Características dos sujeitos participantes da extração de sinais de 5 gestos diferentes e 3 repetições para cada gesto durante a fase de aquisição do primeiro teste. . . . .	69
Tabela 3 – Características dos sujeitos participantes da extração de sinais de 9 gestos diferentes e 4 repetições para cada gesto durante a fase de aquisição do segundo teste. . . . .	75
Tabela 4 – Resultados da melhor rede para a classificação de 2 classes de gestos. . . . .	79
Tabela 5 – Resultados da melhor rede do Cenário 1. . . . .	82
Tabela 6 – Resultados da melhor rede do Cenário 2. . . . .	84
Tabela 7 – Resultados da melhor rede do Cenário 3. . . . .	86



# Lista de abreviaturas e siglas

sEMG	Eletromiografia de superfície (do inglês, <i>Surface Electromyography</i> )
IMU	Unidade de Medida Inercial (do inglês, <i>Inertial Measurement Unit</i> )
ECG	Eletrocardiografia
EMG	Eletromiografia
EEG	Eletroencefalografia
ASL	Linguagem Americana de Sinais (do inglês, <i>American Sign Language</i> )
XAML	Linguagem de programação
MAV	Valor Absoluto Médio (do inglês, <i>Mean Absolute Value</i> )
VAR	Variância (do inglês, <i>Variance</i> )
WAMP	Willison Amplitude
WL	Comprimento da Forma de Onda (do inglês, <i>Waveform Length</i> )
ZC	Cruzamento por Zero (do inglês, <i>Zero Crossing</i> )
AVC	Acidente Vascular Cerebral
MU	Unidade Motora (do inglês, <i>Motor Unit</i> )
IAP	Potencial de Ação Intracelular (do inglês, <i>Intracellular Action Potential</i> )
SVM	Máquina de Vetores de Suporte (do inglês, <i>Support Vector Machine</i> )
MUAP	Potencial de Ação da Unidade Motora (do inglês, <i>Motor Unit Action Potential</i> )
MUAPT	Trem de Potenciais de Ação da Unidade Motora (do inglês, <i>Motor Unit Action Potential Train</i> )
GLCM	Matriz de Co-ocorrência de Níveis de Cinza (do inglês, <i>Gray-Level Co-Occurrence Matrix</i> )
WFT	Transformada por Janelas de Fourier (do inglês, <i>Windowed Fourier Transform</i> )





# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>27</b>
1.1	Contextualização	27
1.2	Justificativa	30
1.3	Objetivo Geral	30
1.4	Objetivos Específicos	30
1.5	Estrutura do documento	31
<b>2</b>	<b>ELEMENTOS DE ANATOMIA E FISILOGIA MUSCULAR</b>	<b>33</b>
2.1	Potencial de Ação	33
2.2	Unidade Motora (MU)	34
2.3	Potencial de Ação da Unidade Motora (MUAP)	34
2.4	Trem de Potenciais de Ação da Unidade Motora (MUAPT)	35
2.5	Sinal Mioelétrico	36
2.6	Eletromiografia Invasiva Versus Não-Invasiva	38
2.7	Eletrodos e Captação de sEMG	39
<b>3</b>	<b>COMPONENTES ELETRÔNICOS</b>	<b>41</b>
3.1	Sensores Inerciais	41
3.1.1	O Acelerômetro	41
3.1.2	O Giroscópio	43
3.1.3	O Magnetômetro	44
3.1.4	Quatérnios	46
3.2	<b>Myo Armband</b>	<b>48</b>
3.3	<b>Aplicações com Myo Armband</b>	<b>49</b>
3.3.1	Algoritmo de estimativa de movimento braço usando o bracelete Myo (KIM; LEE; KIM, 2017)	49
3.3.2	Avaliação de reconhecimento de linguagem de sinais usando o bracelete Myo (ABREU <i>et al.</i> , 2016)	50
3.3.3	Integrando bracelete Myo para o controle de próteses mioelétricas do membro superior (MOURA; SORIANO, 2016)	51
3.3.4	Bracelete de controle de gestos Myo para aplicações médicas (ABDUO; GALSTER, 2015)	51
3.3.5	Comparação de cinco séries cronológicas de extrações de características de EMG usando o bracelete Myo (ARIEF; SULISTIJONO; ARDIANSYAH, 2015)	52

3.3.6	LOVETT: descamação com bracelete MYO para monitorização de terapia de músculos do dedo de pessoas pós acidente vascular cerebral (HIDAYAT; ARIEF; YUNIARTI, 2016) . . . . .	53
<b>4</b>	<b>IDENTIFICAÇÃO DE PADRÕES EM SINAIS DE SEMG . . . . .</b>	<b>55</b>
<b>4.1</b>	<b>Redes Neurais Artificiais . . . . .</b>	<b>55</b>
4.1.1	Funções de Ativação Diferenciáveis . . . . .	56
4.1.2	Arquitetura das Redes Neurais . . . . .	57
<b>4.2</b>	<b>Processo de Aprendizado . . . . .</b>	<b>58</b>
4.2.1	Aprendizado Supervisionado . . . . .	59
4.2.2	Aprendizado Não-supervisionado . . . . .	59
<b>4.3</b>	<b>Wavelets . . . . .</b>	<b>59</b>
4.3.1	Transformada de Fourier . . . . .	60
4.3.2	Transformada Wavelet . . . . .	60
<b>4.4</b>	<b>Matriz de Co-ocorrência de Níveis de Cinza (GLCM) . . . . .</b>	<b>61</b>
<b>5</b>	<b>METODOLOGIA . . . . .</b>	<b>67</b>
<b>5.1</b>	<b>Dispositivos e Softwares . . . . .</b>	<b>67</b>
<b>5.2</b>	<b>Protocolo de Aquisição dos Sinais para o Primeiro Teste . . . . .</b>	<b>67</b>
<b>5.3</b>	<b>Extração de Características dos Sinais . . . . .</b>	<b>69</b>
<b>5.4</b>	<b>Rede Neural para Identificação de Padrões . . . . .</b>	<b>70</b>
<b>5.5</b>	<b>Metodologia Aplicada para o Segundo Teste . . . . .</b>	<b>70</b>
5.5.1	Classes de movimentos . . . . .	70
5.5.2	O Método . . . . .	74
<b>6</b>	<b>RESULTADOS . . . . .</b>	<b>77</b>
<b>6.1</b>	<b>Resultados do Primeiro Teste . . . . .</b>	<b>77</b>
6.1.1	Gráfico de Aquisição dos Sinais . . . . .	77
6.1.2	Resultados da Rede Neural . . . . .	78
<b>6.2</b>	<b>Resultados do Segundo Teste . . . . .</b>	<b>81</b>
6.2.1	Treinamento das redes neurais . . . . .	81
6.2.2	Cenário 1: Diferenciação de 5 classes com características de EMG e cálculo da energia e da potência . . . . .	81
6.2.3	Cenário 2: Diferenciação de 5 classes com características de EMG e IMU e utilização de wavelets e GLCM . . . . .	82
6.2.4	Cenário 3: Diferenciação de 9 classes com características de EMG e IMU e utilização de GLCM . . . . .	84
<b>7</b>	<b>CONCLUSÕES . . . . .</b>	<b>87</b>

**REFERÊNCIAS** ..... 89



# 1 Introdução

Esse capítulo contextualiza o objeto de estudo, descreve os objetivos gerais e específicos abordados e apresenta a formatação utilizada no documento.

## 1.1 Contextualização

O avanço da tecnologia tem possibilitado melhorias na vida de muitas pessoas, seja na área social, econômica, de saúde, entre outras. Entre as tecnologias crescentes está o uso de equipamentos vestíveis (do inglês, *wearables*) de alto contato corporal para realização de movimentos em jogos, robôs, controle de equipamentos e até mesmo para aquisição de sinais biológicos, como a Eletromiografia de Superfície (sEMG, do inglês *Surface Electromyography*).

As pesquisas realizadas têm aumentado em número e são de grande interesse por pesquisadores em todo o mundo, com maior ênfase em países desenvolvidos e que já têm vasto conhecimento em eletrônica, como Estados Unidos, Japão e a Coreia do Sul. No Brasil, estudos acerca da eletromiografia de superfície têm sido desenvolvidas em várias universidades, a saber: UnB, UFRJ, UFBA, UFMG, UFRGS, entre outras.

Pesquisas realizadas em eletromiografia datam do início do século 20. O desenvolvimento da área de Processamento de Sinais possibilitou a melhoria do entendimento acerca dos sinais eletromiográficos. Dessa forma, cresceu muito o número de pesquisadores abordando o tema e que abriram caminho para o estudo mais aprofundado da matéria.

Uma das plataformas vestíveis utilizadas na atualidade é o *Myo Armband*, um dispositivo que tem enfoque na aquisição de sinais eletromiográficos, por meio de oito sensores, que devem ser posicionados no antebraço, tem o formato de um bracelete e também conta com outros discriminadores de movimentos, como a Unidade de Medida Inercial (IMU, do inglês *Inertial Measurement Unit*), composta por acelerômetro, giroscópio e magnetômetro.

A importância de classificar gestos envolve a oportunidade de solucionar problemas de engenharia criados da necessidade da sociedade. Para controlar um dispositivo é preciso estabelecer o meio pelo qual um humano irá interagir com o dado aparelho, quando a interação se dá por meio de sensores, é essencial que o sensor obtenha o reconhecimento daquilo que o usuário faz, caso contrário o usuário não teria o que deseja como resultado de certo gesto, ação ou interação.

Como mostrado na Figura 1, o bracelete Myo já tem sido usado para controle mecânico de próteses. O bracelete foi colocado no braço do sujeito que teve parte do

membro amputado, nesta aplicação foram utilizados dois dispositivos, a prótese utilizada responde bem aos movimentos solicitados pelo sujeito e testes com pequenas bolas foram feitos para avaliar a capacidade de reconhecimento dos movimentos.



Figura 1 – Utilização do bracelete Myo para controle de uma prótese mecânica em pessoas que tiveram parte do braço amputado ou nasceram como má formação.

As unidades de medidas inerciais contam com os sensores acelerômetro, magnetômetro e giroscópio. Cada vez mais estes sensores têm sido utilizados em aplicações de robótica, militares, drones, entre outros. Na Figura 2 é possível observar uma aplicação em que uma IMU foi utilizada na perna de do atleta de remo para se obter a posição da perna em cada instante de tempo e ser possível visualizar o movimento sendo executado no visor presente no aparelho *2ROW*, um remo *indoor* criado por alunos da Universidade de Brasília. A Figura 3 exemplifica um dispositivo que obtém estabilidade a partir da medida dos sensores IMU, além disso seria possível controlá-lo com o bracelete Myo uma vez que os movimentos estivessem classificados.



Figura 2 – Representação do movimento de remada no aparelho *2ROW* criado por alunos da UnB. O aparelho conta com uma estrutura de remo *indoor*, sistemas embarcados, unidade de medidas inerciais alocado na perna esquerda do atleta para avaliação do movimento realizado e visualização do movimento de remado no visor do aparelho.



Figura 3 – Drone contendo uma câmera sobrevoando uma cidade. O controle de um drone acontece remotamente por radiofrequência emitida de uma antena de um controle.

## 1.2 Justificativa

A ausência de funções motoras, controle dinâmico de estruturas robóticas, aprofundamento no estudo da eletromiografia de superfície, controle de jogos por meio de sinais mioelétricos e de movimento são alguns dos motivos para o desenvolvimento deste trabalho.

Analisar a capacidade de interpretação dos sinais adquiridos pelo Myo e transmitidos a partir de Bluetooth para o computador para validar futuras vertentes de testes também estão entre os quesitos a serem analisados.

## 1.3 Objetivo Geral

O presente trabalho tem a função de extrair padrões característicos de movimentos realizados com a mão a partir de medidas aferidas por meio de um dispositivo vestível no antebraço. Os sinais coletados de eletromiografia, acelerômetro, giroscópio e quatérnios serão adquiridos e uma base de dados deverá ser formada. Replicar movimentos padronizados e aumentar o número de classes possíveis para interpretação dos padrões são outro objetivo, também pode-se comparar métodos para processamento de sinais para evidenciar a metodologia melhor aplicável para o presente estudo.

## 1.4 Objetivos Específicos

- Obter dados captados pelos sensores mioelétricos e de movimento (IMU) do Myo Armband e transmitir os sinais para o computador;
- Obter gráficos em tempo real (ou com o mínimo de atraso entre a aquisição) dos sinais captados pelo Myo;
- Identificar movimentos distintos entre duas classes;
- Identificar movimentos distintos entre cinco classes de EMG;
- Identificar movimentos distintos entre nove classes, envolvendo sinais de EMG, quatérnio, acelerômetro e giroscópio;
- Avaliar as abordagens que têm os melhores desempenhos para cada um dos objetivos propostos.



## 1.5 Estrutura do documento

O documento está estruturado em sete capítulos, no capítulo 1 toda a contextualização do que deve ser projetado, os objetivos gerais e os específicos propostos durante o desenvolvimento, além de metas implícitas e explícitas do trabalho, assim como a justificativa do estudo focado em eletromiografia e seu relacionamento com o dispositivo utilizado. O capítulo 2 é referente aos elementos da anatomia e da fisiologia muscular e pontos importantes para o entendimento da musculatura humana na interação com sensores mioelétricos. O Capítulo 3 aborda os componentes eletrônicos presentes no bracelete Myo e o funcionamento de cada um deles. Também exemplifica aplicações já realizadas com o bracelete Myo. O capítulo 4 aborda a identificação de padrões de sinais, conceitos sobre redes neurais artificiais e seus processos de aprendizado, assim como extração de características de sinais;

A partir do capítulo 5 começa uma nova fase do documento, em que a metodologia, resultados e conclusão são realizados. No capítulo 5 é descrita a metodologia para o desenvolvimento de cada função ou código produzido, assim como os gráficos obtidos durante a pesquisa foram abordados neste capítulo. O capítulo 6 apresenta os resultados das etapas do primeiro e segundo testes são observados neste capítulo, contendo gráficos para análise do percentual de erro de validação e dados das taxas de acerto nas comparações de características, quantidade de neurônios capaz de gerar a melhor rede neural e explanação acerca do que se obteve em cada cenário proposto. Por fim, a Conclusão do estudo e explicação sobre o que se entende dos resultados é feita no capítulo 7 e deste modo o documento é encerrado.



## 2 Elementos de Anatomia e Fisiologia Muscular

A fim de estudar os movimentos captados por eletrodos mioelétricos de superfície é preciso entender o funcionamento do corpo humano e a relação que existe entre os tecidos mais próximos à pele, ou seja, aqueles que geram sinais ao se contraírem e se relaxarem. Para tanto, foi proposta uma pequena explanação dos itens mais importantes a respeito da anatomia e da fisiologia muscular. O capítulo ainda apresenta uma introdução sobre os tipos de eletrodos para captação de sinais mioelétricos e também sobre o dispositivo a ser utilizado na pesquisa.

### 2.1 Potencial de Ação

Nas células nervosas existem canais de sódio, canais de potássio, entre outros. Para cada um deles, existe uma tensão para que fiquem abertos ou fechados, dependendo da tensão da membrana.

Também existem os mecanismos de bomba, são os que realizam o transporte ativo de  $K^+$  e  $Na^+$ . Essa operação faz com que a concentração de íons  $Na^+$  fora da fibra muscular e de  $K^+$  dentro da fibra muscular aumente.

Íons são carregados eletricamente e suas diferenças de concentração geram potenciais elétricos, podendo ser positivos ou negativos, dependendo das concentrações presentes. O interior da célula é negativo em relação ao exterior, isso provoca um fenômeno chamado de gradiente potencial através da membrana. Tanto o  $Na^+$  quanto o  $K^+$  são carregados positivamente e se movem da região positiva fora da célula para a região negativa no interior da célula. O fluxo entra em estado de balanço quando o fluxo de  $K^+$  coincide com o fluxo de  $Na^+$ , entrando e saindo da membrana, esse processo pode ser observado na Figura 4.

A condição de equilíbrio é atingida caso a tensão através da membrana seja de 70mV, com polo negativo no interior e polo positivo no exterior([BARBERO; MERLETTI; RAINOLDI, 2012](#)) e manter essa condição requer energia.

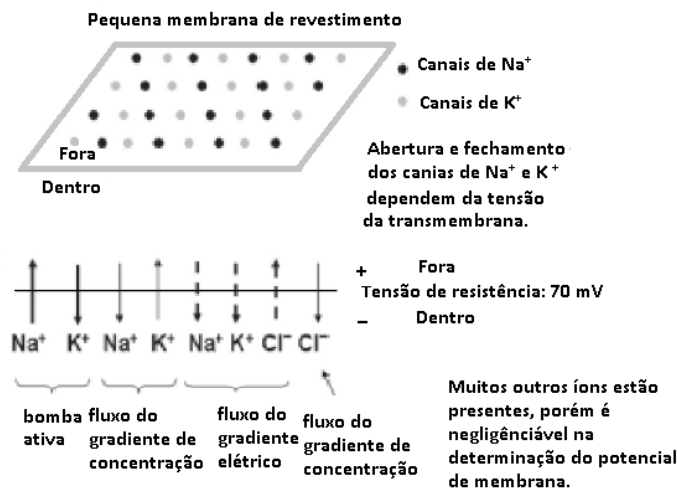


Figura 4 – Representação do potencial de ação na passagem de sódio, potássio e Cloro na camada muscular humana (BARBERO; MERLETTI; RAINOLDI, 2012) adaptado.

## 2.2 Unidade Motora (MU)

Uma unidade motora (MU, do inglês, Motor Unit) consiste de um motoneurônio- $\alpha$  na medula espinhal e o conjunto das fibras musculares por ele inervadas. O motoneurônio- $\alpha$  origina o potencial que ativa a contração das fibras musculares que compõem a unidade motora (MERLETTI, 2004), como representado na figura 5.

Um músculo pode ter entre cem e mil unidades motoras, depende do tamanho do músculo. Músculos da mão, por exemplo, não tem muito mais que cem MU's, enquanto um músculo mais longo pode ter até mil unidades motoras (BARBERO; MERLETTI; RAINOLDI, 2012). Estudos anteriores mostraram as diferenças entre 3 tipos de unidades motoras, para tal, foram consideradas características de velocidade de contração e fadiga, são elas:

- Contração muscular rápida e fatigante (FF);
- Contração muscular rápida e resistente à fadiga (FR);
- Contração muscular lenta e mais resistente à fadiga (S).

## 2.3 Potencial de Ação da Unidade Motora (MUAP)

O Potencial de Ação da Unidade Motora (MUAP, do inglês, *Motor Unit Action Potential*), é a soma de todas as contribuições providas pelas fibras individuais que for-

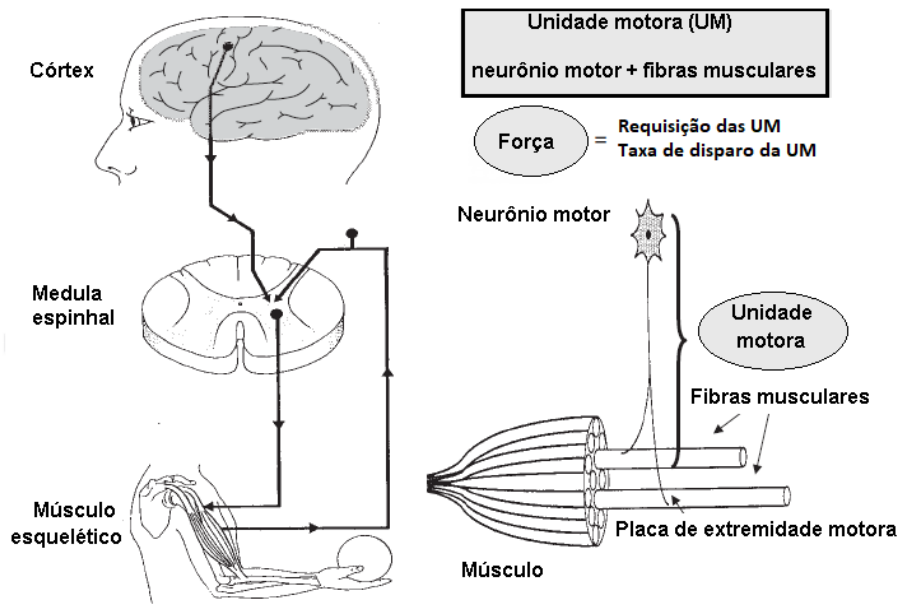


Figura 5 – Esquemático básico da representação de uma unidade motora e seus componentes, desde a ativação no córtex, passando pela medula espinhal até cada unidade motora dos músculos (MERLETTI, 2004) adaptado.

mam a unidade motora (BARBERO; MERLETTI; RAINOLDI, 2012). Os músculos são formados por muitas unidades motoras, que consistem de um motoneurônio e um grupo de fibras musculares, as fibras das unidades motoras são ativadas em conjunto, por esse motivo, quando são ativadas, formam o que chamamos de MUAP.

## 2.4 Trem de Potenciais de Ação da Unidade Motora (MUAPT)

A atividade elétrica de uma única unidade motora é caracterizada pelo tempo padrão em que cada potencial de ação é repetidamente ativado pelas fibras musculares e pelas contrações. O padrão de disparo pode revelar a descrição estatística na forma de uma soma de funções impulso unitárias ocorridas em tempos aleatórios  $t_k$ ,

$$d\mathbf{E}(t) = \sum_{k=1}^M \delta(t - t_k), \quad (2.1)$$

em que  $M$  é o número total de MUAP que ocorrem em um trem de impulsos. A representação  $d\mathbf{E}(t)$  às vezes também é referido como uma série de eventos (SORNMO; LAGUNA, 2015).

O trem de potenciais de ação da unidade motora (MUAPT, do inglês, *Motor Unit Action Potential Train*) pode então ser representado como a convolução dos impulsos, cuja ocorrência apresenta caráter estocástico, com o sinal característico da unidade motora, como representado na Figura 6.




Figura 6 – Geração do trem de impulsos (SORNMO; LAGUNA, 2015) adaptado.

Portanto, como ocorrem diversos sinais ao mesmo tempo, o conjunto de todos os trens de impulsos somados gera o sinal mioelétrico, podendo então ser captado, seja na superfície da pele, a exemplo do objeto de estudo deste trabalho, seja invasivo, método bastante explorado no ambiente clínico.

## 2.5 Sinal Mioelétrico

O sinal eletromiográfico é a representação de um potencial elétrico gerado por meio da despolarização da membrana externa da fibra muscular. Sua detecção envolve o uso de eletrodos intramusculares ou de superfície, os quais são colocados a certas distâncias das fontes. O tecido que separa as fontes e os eletrodos de gravação age como um filtro do volume condutor. As propriedades de volume condutor determinam as características do que é detectado na superfície da pele, como por exemplo o conteúdo de frequência (FARINA; MERLETTI, 2016).

O sinal de EMG é gerado pela atividade elétrica das fibras musculares durante a contração. As fontes de sinal são as zonas despolarizantes e repolarizantes das fibras musculares. As fontes de sinal são separadas dos eletrodos de captação por um tecido biológico, que age como um filtro passa-baixas temporal e espacial no potencial de distribuição (FARINA; MERLETTI, 2016). A representação das contribuições individuais e a soma das contribuições é representada na Figura 7.

Um potencial em torno de 70 mV a 90 mV pode ser medido no interior das células musculares. A manutenção desse potencial é mediado pela bomba de sódio-potássio trabalhando contra a concentração gradiente do fluxo de íons através da membrana. quando o potencial de ação gerado pelo neurônio motor atinge a junção neuromuscular, isso causa uma emissão de acetilcolina no fosso entre o nervo terminal e a membrana de fibra muscular.

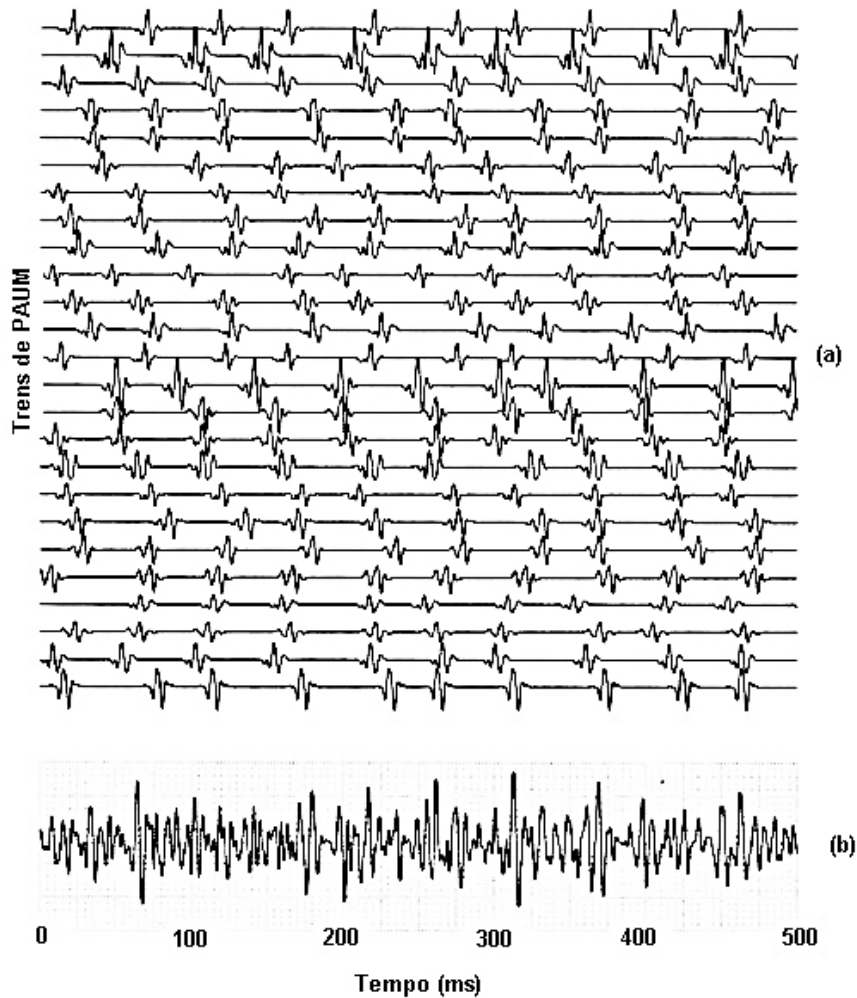


Figura 7 – (a) Diversos trens de impulso sendo captados separadamente; (b) Sinal mioelétrico completo da aquisição em um músculo esquelético humano (SORNMO; LAGUNA, 2015) adaptado.

Acetilcolina excita a fibra muscular, então o gradiente potencial é localmente gerado na fibra. A densidade de corrente para dentro corresponde a esse potencial gradiente, como mostrado na Figura 8. A zona de depolarização se propaga nas fibras musculares das junções neuromusculares para o final dos tendões. Esse potencial de ação de propagação intracelular (IAP, do inglês *Intracellular Action Potential*) causa uma corrente iônica que se propaga através da membrana plasmática das células do tecido muscular estriado. Para fibras musculares, o comprimento da despolarização e repolarização é da ordem de milímetros. No entanto, a fibra muscular pode ser considerada como um tubo muito fino em que a corrente flui axialmente.

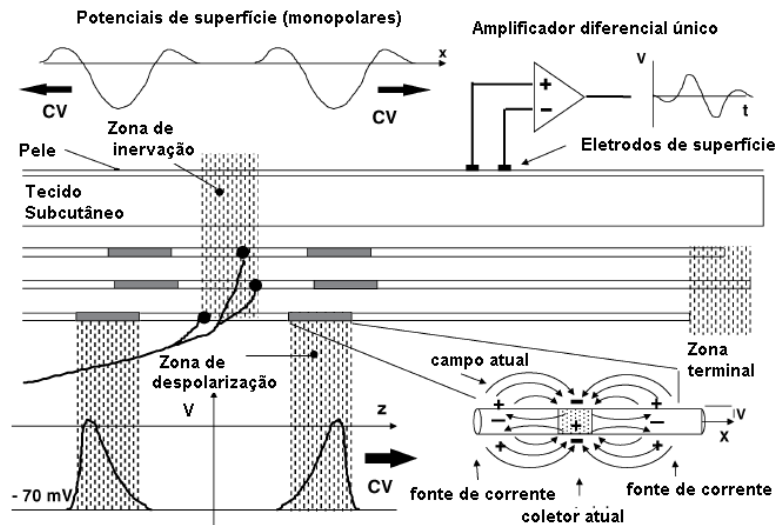


Figura 8 – Representação de uma unidade motora e do potencial de ação da unidade motora como elementos da eletrônica de funcionamento conhecido (FARINA; MERLETTI, 2016) adaptado.

## 2.6 Eletromiografia Invasiva Versus Não-Invasiva

A eletromiografia pode ser detectada por eletrodos intramusculares ou por eletrodos colocados sobre a superfície da pele. A inserção de eletrodos diretamente no músculo permite que a detecção dos potenciais elétricos seja muito próxima à fonte, o que torna a influência do volume de condução nas fontes de corrente das fibras membrânicas mínima. Por essa razão o potencial de ação das diferentes MUs são razoavelmente separados no tempo e podem ser identificados relativamente fáceis nas forças médias e baixas (FARINA; MERLETTI, 2016).

Na eletromiografia de superfície, ao se utilizar eletrodos não invasivos atuando somente sobre a pele, surgem algumas dificuldades relativas a distância entre a fonte dos sinais, que são os músculos, e a captação, que já não está diretamente relacionada ao local do sinal. Para minimizar problemas de interferência causados exatamente por haver outras unidades motoras em movimento entre o ponto de captação e o local do músculo que se quer obter sinais são utilizadas técnicas como a *powerline* e compensação espacial com filtros passa-baixas. Para captar determinado sinal, geralmente se utiliza uma combinação linear de sinais captados em mais de um eletrodo, no entanto, também existe a captação monopolar.

O tamanho físico do eletrodo também influencia o sinal de EMG, caso a impedância eletrodo-pele entre o material do eletrodo e a superfície da pele seja uniformemente distribuída e baixa comparada à impedância do amplificador, mas alta comparada à impedância do tecido, o potencial medido pelo eletrodo é aproximadamente igual ao potencial médio medido na superfície da pele abaixo disso (FARINA; MERLETTI, 2016). Como



consequência, a influência do tamanho do eletrodo pode ser modelada como um filtro passa-baixas espacial, segundo o qual a dimensão do eletrodo define a forma do filtro.

## 2.7 Eletrodos e Captação de sEMG

As características do sinal de EMG dependem do número de parâmetros anatômicos, físicos e de detecção. Os mais importantes desses fatores são: a espessura do tecido subcutâneo, a profundidade da fonte no músculo, distância da fonte dos eletrodos, a inclinação do sistema de detecção com relação à orientação da fibra muscular, o tamanho da fibra, a localização dos eletrodos sobre o músculo, o filtro usado para detecção, o tamanho do eletrodo, o seu formato e o cruzamento entre músculos próximos ([FARINA; MERLETTI, 2016](#)).



## 3 COMPONENTES ELETRÔNICOS

### 3.1 Sensores Inerciais

A categoria de sensores inerciais baseados em sistemas microeletromecânicos é representada, principalmente, por dois dispositivos: acelerômetro e giroscópio. Já o magnetômetro é aplicado em IMUs para melhorar a qualidade e a exatidão do sinal de saída dos sensores inerciais.

**Acelerômetros:** capazes de aferir a aceleração linear na direção de um eixo referencial. Aceleração é a taxa de variação da velocidade no tempo, representada em  $m/s^2$  (metro por segundo ao quadrado) no Sistema Internacional de Unidades.

**Giroscópios:** capazes de medir a velocidade angular em torno de um eixo de referência. A velocidade angular é uma grandeza que representa a taxa de variação da posição angular no tempo, cuja unidade de medida no Sistema Internacional de Unidades é o  $rad/s$  (radianos por segundo).

**Magnetômetros:** capazes de medir a intensidade, direção e sentido de campos magnéticos em sua proximidade, cuja unidade no Sistema Internacional de Unidades é G (Gauss). Apesar de não ser um sensor do tipo inercial, o magnetômetro é bastante utilizado em sistemas de rastreamento de movimentos em conjunto com o acelerômetro e giroscópio.

#### 3.1.1 O Acelerômetro

Um acelerômetro é um dispositivo eletromecânico capaz de medir aceleração, isto é, a taxa de variação da velocidade. Estas acelerações podem ser estáticas, como a força da gravidade, ou dinâmicas, causadas por movimentação ou vibração. Sua unidade no Sistema Internacional (SI) é  $m/s^2$ , mas em muitos casos o valor de aceleração é especificado como um fator multiplicativo de “g”. Nesse sentido, “g” é uma unidade de aceleração que equivale a força de gravidade da Terra ao nível do mar ou  $9,81m/s^2$ .

Basicamente, todos os tipos de acelerômetros traduzem o sinal externo de aceleração em um deslocamento correspondente de sua massa móvel, também conhecida como massa inercial ou de prova. Este deslocamento pode ser detectado através de diferentes esquemas de medição, sendo que os mais comuns são: capacitivo, piezoelétrico, piezoresistivo, ressonante e óptico (YADI; AYAZI; NAJAFI, 1998).

Geralmente ao usarem-se acelerômetros o desenvolvedor procura extrair a aceleração linear, essa aceleração é somente aquela aplicada no sensor descontando a aceleração

da gravidade. Essa aceleração, dependendo do dispositivo, pode ser medida nas três dimensões, e se não fosse pela sua falta de precisão poderia ser facilmente utilizado para medir velocidade e deslocamento (FUX, 2008).

Ao trabalhar com essa aceleração linear, geralmente é onde se encontra o primeiro problema, uma vez que o sensor tem uma precisão duvidosa, e possui seus eixos próprios de x, y e z diferentes dos eixos relativos a terra, é difícil dizer com precisão que intensidade a força gravitacional está aplicando em cada um desses eixos do sensor.

Sensores são partes fundamentais de um sistema de controle e precisam medir de forma aceitável a variável de interesse. Apesar de apresentarem boa exatidão, acelerômetros microfabricados podem produzir erros que inviabilizariam o seu uso. A caracterização desses dispositivos é importante para que se conheçam bem suas peculiaridades e assim determinar se é válida a sua utilização em uma determinada aplicação.

Acelerômetros encontram aplicações tanto no setor militar (guiamento de mísseis e navegação inercial) quanto no setor civil. Na indústria podem ser utilizados para a monitoração de vibrações em máquinas e equipamentos, em automóveis são utilizados no mecanismo de disparo de air bags e em ensaios de colisão. Até mesmo na área da saúde esses dispositivos são encontrados auxiliando o estudo de distúrbios do sono e detecção de variáveis fisiológicas (FIGUEIREDO *et al.*, 2007).

Observando a Tabela 1 pode-se perceber que as aplicações de acelerômetros são bem variadas assim como suas características desejáveis.

Tabela 1 – Aplicações típicas para acelerômetro e suas características desejáveis em cenários diferentes de atuação. A primeira coluna evidencia a aplicação, na segunda é possível observar a banda de atuação em que o acelerômetro tem funcionamento, a terceira coluna mostra a resolução do sensor, ou seja, a menor unidade de medida possível de leitura e a quarta coluna destaca o máximo de gravidade mensurável pelo sensor (BEEBY *et al.*, 2004).

Aplicação	Banda	Resolução	Alcance dinâmico
Air bag	0 - 0,5 kHz	< 500 mg	+ - 100 g
Controle de estabilidade de automóveis	0 - 0,5 kHz	< 10 mg	+ - 2 g
Navegação inercial	0 - 100 Hz	< 5 $\mu$ g	+ - 1 g
Aplicações médicas	0 - 100 Hz	< 10 mg	+ - 100 g
Medida de vibrações	1 - 100 kHz	< 100 mg	+ - 10 <sup>4</sup> g
Realidade virtual	0 - 100 Hz	< 1 mg	+ - 10 g
Medida de microgravidade	0 - 10 Hz	< 1 $\mu$ g	+ - 1 g
Munição inteligente	10 Hz - 100 kHz	< 1 g	+ - 10 <sup>5</sup> g
Monitoração de pacotes frágeis	0 - 1 kHz	< 100 mg	+ - 10 <sup>3</sup> g

Em aplicações que requerem maior resolução e estabilidade, como detecção de terremotos, sistemas de navegação inercial e obtenção de perfis de reflexão sísmica, o mais indicado é o uso de acelerômetros baseados em estruturas vibrantes (MAENAKA, 2007).

### 3.1.2 O Giroscópio

Um giroscópio consiste essencialmente em um rotor perfeitamente balanceado que pode girar livremente em torno de seus eixos geométricos perpendiculares entre si que se interceptam no seu centro de gravidade. Quando colocado numa suspensão tipo Cardan, um giroscópio pode adquirir qualquer orientação, mas seu centro de massa deve permanecer fixo no espaço. A agulha giroscópica desenvolvida no início do século passado é exemplo de uma das primeiras aplicações formais do giroscópio e suas propriedades. São exploradas duas propriedades básicas do giroscópio. São elas a inércia giroscópica e a precessão estacionária:

- A inércia giroscópica faz com que o rotor tenda a conservar sua direção no espaço, por mais variados que sejam os movimentos impostos à sua base. Em outras palavras, a inércia giroscópica (ou rigidez no espaço) é a propriedade que o giroscópio livre tem em manter seu eixo apontado sempre para um mesmo ponto no espaço, a despeito dos movimentos de sua base.
- Precessão pode ser definida como o movimento resultante do rotor, quando é aplicada uma força que tende a alterar a direção do seu eixo de rotação. Em virtude desta propriedade, quando é aplicada ao rotor uma força tendendo a deslocar o eixo de rotação de sua direção no espaço, em vez do eixo se mover na direção da força, o fará num plano perpendicular à direção da força aplicada.

Além de possuírem aplicação em bússolas, aeronaves, sistemas de posicionamento global (GPS), etc., os giroscópios foram introduzidos atualmente em produtos eletrônicos de consumo em massa. Uma vez que o giroscópio permite o cálculo de orientação e rotação, fabricantes incorporaram-no na tecnologia moderna. A integração do giroscópio permitiu maior acurácia de reconhecimento de movimento num espaço de três dimensões (3D) que o anterior acelerômetro somente. Agora, nesses aparelhos, os giroscópios são frequentemente combinados com os acelerômetros (sensores de aceleração).

Estruturalmente, um giroscópio é similar a um acelerômetro, possuindo, também, uma massa de prova suportada por molas de silício. A principal diferença é que a velocidade angular é obtida medindo-se a força Coriolis exercida na massa vibrante, ou seja, o movimento do corpo de prova deve possuir, pelo menos, dois graus de liberdade (ACAR; SHKEL, 2009).

A versão clássica de um giroscópio consiste em um disco (rotor) montado em uma estrutura que provê 3 graus rotacionais de liberdade. Ao ser girado, o disco tende a continuar em rotação na mesma orientação, devido à conservação de momento angular. Assim, como o mecanismo é feito de modo a minimizar o atrito nas juntas dos arcos, quando a estrutura é girada, o disco continua na mesma orientação, girando quase independentemente do resto da estrutura. Deste modo é possível medir o ângulo entre o eixo de rotação do disco e os arcos mais externos e determinar quanto a estrutura girou em relação a sua orientação original. Os arcos de suspensão são chamados gimvais .

Os giroscópios microeletromecânicos, por sua vez, podem ser construídos de diversas maneiras. Uma das mais simples e baratas é a que utiliza microestruturas vibrantes. Ao invés de um disco girante, este tipo de giroscópio usa uma massa de prova que oscila apenas em uma direção. Há dois conjuntos de molas de silício:  $K_x$ , suportando a estrutura externa e conferindo mobilidade na direção do eixo  $x$ ; e  $K_y$  permitindo uma constante vibração da parte interna na direção do eixo  $y$ , causada por atuadores eletrostáticos. A força Coriolis proveniente de uma rotação em torno do eixo  $z$  faz com que tanto a parte central quanto a parte externa da estrutura se movam na direção  $x$ . Este movimento da parte externa causa uma variação da capacitância entre eletrodos fixos e móveis conectados a esta parte da estrutura, essa variação da capacitância é processada, filtrada e digitalizada, produzindo o sinal de saída do giroscópio.

O papel do giroscópio é prover a característica do movimento a curto prazo, ou movimentos rápidos. Giroscópios são muito menos suscetíveis a ruídos que os acelerômetros, e apresentam a resposta mais rápida e tem maior estabilidade. No entanto, como as leituras de um giroscópio fornecem a velocidade angular, é necessário fazer a integração dessas medidas para se obter o ângulo de rotação do sistema o que introduz erros cumulativos de integração. Assim, a longo prazo, a estimativa baseada puramente em giroscópios deriva do valor real. A deriva ou erro em relação ao valor real é conhecido como drift, que é uma característica inerente aos sensores. De forma geral, quanto melhor forem os componentes, a montagem e a confecção do sensor, menor é drift do mesmo, entretanto isso implica em um aumento exponencial do preço total do dispositivo.

### 3.1.3 O Magnetômetro

Magnetômetros são dispositivos empregados na medição da intensidade, direção e sentido de campos magnéticos. Magnetômetros são amplamente utilizados para medir o campo magnético da terra. Há dois tipos de magnetômetros: escalares e vetoriais; enquanto que os magnetômetros escalares medem apenas a magnitude do campo magnético, os vetoriais são capazes de medir a magnitude e sentido do campo magnético na direção em que estão alinhados.

Os Magnetômetros podem ter diversos princípios de funcionamento, como por

exemplo os magnetômetros de Efeito Hall, de bobina rotativa e de precessão protônica (RIPKA, 2009). O efeito Hall foi descoberto em 1879 por E. H. Hall. Aplicando um campo magnético perpendicular à direção da corrente elétrica em um semicondutor elétrico induz uma diferença de potencial elétrico nas laterais do condutor conforme ilustra a Figura 9.

De um modo geral, um magnetômetro é formado por um conjunto de equipamentos usados para medir o momento magnético de uma amostra para um determinado valor de campo magnético aplicado.

Os componentes básicos de um magnetômetro são:

- Fonte de Corrente
- Eletroímã
- Sensor de Campo Magnético
- Sistema para movimentação de amostra

O funcionamento básico de um magnetômetro pode ser descrito da seguinte forma: a fonte fornece corrente elétrica para as bobinas do eletroímã que geram um campo magnético na região onde se encontra a amostra. A amostra é magnetizada e por sua vez produz um campo induzido que é lido pelo sensor. Através deste campo induzido e de um modelo teórico, obtemos o momento magnético da amostra para cada valor de campo aplicado. Os sensores magnéticos possuem uma sensibilidade de acordo com alguns parâmetros. Os mais importantes são, eletrônica para a leitura dos diferentes campos magnéticos e geometria.

Existem vários tipos de magnetômetros que são bem diferentes entre si nos aspectos de construção e custo. Portanto, na hora da compra do sensor, deve-se levar em consideração, a aplicação, resolução desejada e o tamanho físico.

Magnetômetros usualmente são aplicados em Unidades de Medição Inercial, porém esses sensores não classificados como sensores inerciais, já que estes não fazem medições inerciais e sim, são capazes de sentir o campo magnético terrestre e de outros equipamentos.

A inserção de magnetômetros corrige a deriva da posição angular, da fusão sensorial entre o acelerômetro e giroscópio, ao redor do eixo da força gravitacional. O acelerômetro não é capaz de corrigir a deriva em rotações ao redor deste eixo, pois o vetor aceleração observado por um objeto é invariante a rotações sobre eixo de gravidade. Por exemplo, um veículo trafegando em uma esfera perfeita sempre observará o vetor da aceleração gravitacional apontando para dentro da esfera, paralelamente ao seu próprio eixo vertical. O magnetômetro inclui a direção do norte magnético da terra como elemento de correção no sistema.

### 3.1.4 Quatérnios

Quatérnios são uma extensão do conjunto dos números complexos, compostos por uma parte escalar e uma parte vetorial e podem ser representados como mostra a Equação 3.1:

$$q = w + xi + yj + zk \quad (3.1)$$

Onde:

w é a unidade escalar;

xi, yj, zk é a parte vetorial;

w,x,y,z são unidades reais;

i, j, k são unidades imaginárias e seguem a relação  $i^2 = j^2 = k^2 = -1$ .

Os quatérnios podem ser utilizados como uma alternativa aos métodos de representação do espaço tridimensional, são mais intuitivos e econômicos em relação ao uso de memória e tempo de processamento se comparados à outros métodos, como por exemplo, os ângulos de Euler. (FRANQUEIRA, 1993)

De forma geral, o quatérnios estimado por sensores de orientação descreve uma rotação do sistema de referência inercial inicial, para o sistema de referência inercial do corpo do sensor. O sistema de referência inicial é o sistema de coordenadas fixo da terra, definido como o eixo x apontando para o norte, o eixo y apontando para o leste e o eixo z apontando para baixo, como é mostrado na Figura 9. Já o sistema de referência inercial do corpo do sensor se mantém alinhado ao próprio sensor e não se altera durante as rotações. Uma rotação pura em um espaço tridimensional pode ser descrita por um quatérnio unitário.

Quatérnio unitário é um quatérnio que tem a soma da raiz quadrada dos quadrados de cada um de seus componentes igual a 1, ou seja, todos os quatro componentes do quatérnio são divididos pela magnitude do mesmo. quatérnio unitário é uma notação matemática simples, capaz de descrever a orientação de corpos rígidos em um espaço tridimensional, considerando que a rotação do objeto acontece em uma hipersfera com raio de valor unitário.

Rotações no espaço tridimensional podem ser descritas de diversas formas, tais como, ângulos de Euler, matrizes de rotação e transformação, eixos e ângulos e quatérnios. Cada um desses sistemas apresenta suas vantagens e desvantagens. Para a concepção desse projeto, a orientação de objetos e corpos rígidos no espaço será descrita no sistema numérico dos quatérnios. Em um primeiro momento pode ser difícil compreender o funcionamento dos quatérnios e suas operações já que se trata de um sistema de quatro






Figura 9 – Representação do sistema de referência inercial utilizando um avião para demonstrar os movimentos. Roll é a rotação ao redor do eixo longitudinal, eixo X. Pitch é a rotação ao redor do eixo transversal, eixo Y. Yaw é o nome dado à rotação ao redor do eixo vertical, eixo Z (ROBOTICS, 2016) adaptado.

dimensões, entretanto esse sistema apresenta diversas vantagens em relação as matrizes de rotações e ângulos de Euler.

- O processo de concatenar rotações é computacionalmente mais barato e numericamente mais estável;
- Como o problema de Gimbal Lock está ligado a representação matricial dos ângulos de Euler, esse problema não aparece na representação por quatérnios;
- Ausência de ambiguidade;
- É possível extrair o eixo e o ângulo de rotação de um quatérnio unitário;
- O processo de interpolação entre dois quatérnios é mais direto.

Por meio de um estudo sobre a anatomia do corpo humano, corpos rígidos e rotações no espaço, sabe-se que todo o movimento de qualquer segmento do corpo pode ser descrito através da rotação do mesmo sobre um eixo fixo, como ilustrado na Figura 7, por esta razão que o sistema numérico dos quatérnios foi utilizado neste trabalho.

## 3.2 Myo Armband

Myo Armband, visto na Figura 11, é um dispositivo vestível monitor de gestos, capaz de captar sinais sobre os músculos do antebraço através de seus oito sensores de eletromiografia, como mostrado em cada numeração na Figura 8. Movimentos de rotação e translação são entendidos a partir dos sensores de sua unidade IMU: giroscópio, um acelerômetro de três eixos e um magnetômetro de três eixos. Toda essa tecnologia permite a localização de movimentos completos no braço. A comunicação com o computador quando o Myo está carregado se dá através de um adaptador Bluetooth conectado ao USB.

Os movimentos básicos reconhecidos pelo Myo são os seguintes: mão aberta, mão fechada, mão à direita, mão à esquerda e duplo clique dos dedos. Os movimentos podem ser personalizados a partir do software *Myo Connect* para realizar diferentes tarefas no computador.




Figura 10 – Ilustração de identificação dos sensores do *Myo Armband*, o sensor número 4 tem um identificador luminoso para marcar o sensor de referência ao se colocar o bracelete no braço humano (SUNDSTROM, 2015) adaptado.

Existem diversos aplicativos em várias plataformas aceitas pelo Myo, como Windows 7, 8 e 10, Mac, Ios e Android. Esses aplicativos têm funções básicas como aumento de volume, controle de slide, aplicações em jogos, etc. Para suprir a demanda de utilização o Myo conta com uma bateria de Lítio que tem carga suficiente para uso durante um dia inteiro. O processador do dispositivo é um ARM Cortex M4.



Figura 11 – Vista Inferior do Myo *Armband* utilizado durante as etapas de TCC 1 e TCC 2 do presente estudo.

### 3.3 Aplicações com Myo Armband

Alguns artigos da literatura científica que tratam de eletromiografia de superfície foram estudados e resumidos para melhor entendimento das aplicações possíveis utilizando o Myo *Armband* e estão listados a seguir.

#### 3.3.1 Algoritmo de estimativa de movimento braço usando o bracelete Myo (KIM; LEE; KIM, 2017)

A partir de estudos realizados em vastas áreas do conhecimento, percebeu-se a importância da interação baseada no usuário e suas crescentes aplicações em realidade virtual, reconhecimento de sinais biológicos, interação tridimensional, e outros avanços nas áreas de eletroencefalografia (EEG), eletrocardiografia (ECG), eletromiografia (EMG), notou-se a facilidade com que medições na superfície da pele podiam ser feitas para identificar sinais musculares e aplicar sensores na superfície do braço para captar sinais e interpretá-los para uma finalidade específica.

Existem estudos para reconhecimento da posição da mão, movimento da mão, extensão dos dedos, entre outros, utilizando como base transformadas *wavelets*, entretanto, o presente estudo olha para o reconhecimento da posição do antebraço, tendo como referência a parte superior do braço. Para isso, utilizou-se o dispositivo Myo, colocado na altura do bíceps enquanto o sensor IMU presente no Myo supõe a posição do braço.

A partir dos estímulos captados Myo e processados deve-se obter um ângulo de

representação do antebraço. Sabendo-se que o braço pode estar em 2 posições, 0° ou 90° e o antebraço em 3 posições: 0° 45° e 90°, obtém-se, então, uma combinação de 6 posições possíveis.

Vários algoritmos foram utilizados para processar o sinal de eletromiografia advindo do Myo, com eles foi possível gerar resultados satisfatórios para interpretar as posições do braço e antebraço de forma a viabilizar futuras utilizações do dispositivo Myo para mais aplicações.

### 3.3.2 Avaliação de reconhecimento de linguagem de sinais usando o bracelete Myo (ABREU *et al.*, 2016)

Uma grande barreira ainda existente é a dificuldade de comunicação entre falantes e mudos. Pensando nisso o projeto foi desenvolvido. Utilizando o bracelete Myo, planejou-se utilizá-lo para traduzir sinais da Língua Brasileira de Sinais (LIBRAS) para 20 sinais estáticos.

Mudos utilizam a língua de sinais todos os dias para se comunicarem e seria interessante mapear estes movimentos, isso permitiria interações para aplicações de tradução da língua de sinais.

O dispositivo Myo é um *wearable* de fácil utilização, grande potencial e preço baixo, isso faz com que o trabalho proposto tenha grandes chances de evoluir nesse caminho.

O alfabeto de LIBRAS contém as 26 letras do alfabeto utilizado no Brasil, no entanto, 6 desses sinais não são estáticos, ou seja, necessitam de um movimento do braço para serem executados, são os sinais das letras H, J, K, X, Y e Z, por isso foram deixados de lado e o foco de tradução desta pesquisa foram os outros 20 sinais.

A grande maioria dos atuais reconhecedores de movimentos utiliza câmeras e técnicas de visualização computacional, tanto para adquirir quanto para processar esses sinais, porém, um grande problema é que essas técnicas são reféns das condições locais, como iluminação e cores dos objetos da cena captada. O sensor Myo já havia sido utilizado para obter a classificação da *American Sign Language* (ASL, Língua Americana de Sinais) e também para traduzir 10 diferentes sinais da língua Tailandesa de Sinais.

Para treinar o sistema classificador de LIBRAS foi utilizada uma Máquina de Vetores de Suporte (SVM, do inglês, *Support Vector Machine*), um classificador binário poderoso que separa os sinais em zonas. Todos os testes foram realizados em laboratório, o que melhora a performance. O de aprendizado para cada letra contou com aproximadamente 28.500 amostras de sinais do bracelete Myo.

Após a etapa de classificação e aprendizado, foi criada uma aplicação de gestos em tempo real. O resultado da interpretação dos sinais foi diversificado uma vez que

para muitos sinais a precisão de acerto foi baixa, tendo-se repetido o experimento para se chegar a quantidade aceitável de testes, para outros sinais a taxa de acerto chegou a 95%.

A conclusão do experimento é que por maiores vantagens que o Myo tem em ser portátil, barato e não depender de condições do ambiente, faz-se necessário, para melhor performance, de uma combinação com outros dispositivos pois somente a utilização do Myo deixou a real funcionalidade a desejar e notou-se a dificuldade de se perceber a posição acurada dos dedos somente com sEMG.

### 3.3.3 Integrando bracelete Myo para o controle de próteses mioelétricas do membro superior (MOURA; SORIANO, 2016)

O trabalho proposto no artigo foi o de analisar dados advindos do dispositivo Myo e fazer com que um braço mecânico impresso com uma impressora 3D seja movimentado, tudo isso com baixo custo pois o Myo é barato quando comparado com outros dispositivos que desempenham a mesma função e a prótese é de código aberto, portanto algo que já está em parte pronto.

A ideia de fazer o controle de uma prótese a partir de sinais eletromiográficos é antiga, começou entre os anos 50 e 60, porém, foi necessário evoluir a tecnologia para atender às demandas para tal criação.

A interface para leituras foi construída em C# e oferece informações relacionadas aos sinais adquiridos como visualização e potência do sinal, qualidade dos gestos computados, diferenciação através do índice Davies-Bouldin.

Os sinais foram captados através do Myo e transmitidos por Bluetooth para o computador contendo o *Myo-Analyzer*. Já os comandos traduzidos são enviados para a prótese que é controlada por servomotores e por um arduino Mega.

Os resultados mostram que conforme mais treinos e mais dados são adquiridos, melhor é a performance no quesito de acertos da prótese mecânica, dessa forma a acurácia se torna melhor ao longo do uso. Também nota-se que as pesquisas pró amputados têm vastas regiões para melhorar e necessita de atenção da comunidade de engenharia biomédica.

### 3.3.4 Bracelete de controle de gestos Myo para aplicações médicas (ABDUO; GALSTER, 2015)

A busca por métodos de reconhecimento de sinais elétricos para funcionamento de próteses tem aumentado, pesquisas mostram comparações entre diferentes modos de captar e processar os sinais de eletromiografia de superfície.

Ao se estudar o relacionamento entre sEMG e a movimentação dos dedos, avanços foram constatados. Recentemente foi possível mostrar que com 19 eletrodos, pode-se obter 90% de acurácia na determinação do movimento dos dedos em amputados.

O artigo pretende melhorar a atuação do NinaPro (*do inglês, Non-Invasive Adaptive Hand Prosthetics*), um dispositivo que se baseia em sinais de eletromiografia de superfície e controla próteses a partir desses sinais.

As soluções para o problema foram feitas em C# e XAML no VISUAL STUDIO e a escolha foi referenciada nos trabalhos anteriores já realizados, ou seja, porque tornou-se uma prática trabalhar com essas linguagens para trabalhar com eletromiografia aplicada ao dispositivo Myo.

Após todas as etapas de implementação, concluiu-se que os resultados foram satisfatórios para pesquisa e melhor conhecimento do assunto, porém, o dispositivo Myo dificilmente teria acurácia necessária para definir bem os movimentos de perdidos em amputados.

### 3.3.5 Comparação de cinco séries cronológicas de extrações de características de EMG usando o bracelete Myo ([ARIEF; SULISTIJONO; ARDIANSYAH, 2015](#))

O estudo realizado por pesquisadores da Indonésia evidencia a diferença na extração de sinais do Myo Armband utilizando cinco diferentes métodos, são eles: Valor Absoluto Médio (do inglês, *Mean Absolute Value*), Variância (VAR), Willison Amplitude (WAMP), Comprimento da Forma de Onda (do inglês, *Waveform Length*) e Cruzamento de Zero (do inglês, *Zero Crossing*).

A intenção era fazer a comparação entre os cinco métodos de extração de sinais quando a mão faz alguns movimentos. Diferentemente dos movimentos mais comuns já observados pelo Myo, utilizou-se posições novas das mãos, que geram novos sinais nos leitores do Myo, são eles: punho fechado, punho aberto, dedo médio dobrado, posição de arma, meio punho.

Faz-se dez vezes os cinco movimentos e então os dados são enviados para o computador através do Bluetooth e gera cinco extrações características, essas características serão comparadas com um padrão anterior de gestos e, se houver diferenças significativas, deve ser notado.

Ao retirar conclusões notou-se que os melhores métodos para extração de parâmetros do Myo foram, em primeiro lugar, MAV, seguido do método WL. Os demais não apresentaram a mesma colocação em todos os experimentos, se misturando para as diferentes tentativas.

### 3.3.6 LOVETT: descamação com bracelete MYO para monitorização de terapia de músculos do dedo de pessoas pós acidente vascular cerebral (HIDAYAT; ARIEF; YUNIARTI, 2016)

Pacientes que uma vez tenham tido um acidente vascular cerebral apresentam muito comumente dificuldades nos movimentos de partes do corpo. Isso acontece porque a região do cérebro em que houve morte de células, seja causada por hemorragia ou pela falta de irrigação sanguínea, é a responsável pelos dados movimentos.

Para que um médico ou fisioterapeuta tenha noção da força que um paciente consegue exercer no braço foi criado o procedimento LOVETT (HIDAYAT; ARIEF; YUNIARTI, 2016), ele funciona como uma escala para comparar e medir a força muscular do braço e evidenciar isso para o responsável. No artigo, o bracelete *Myo Armband* é utilizado para fazer medidas mais precisas e informar aos especialistas qual a real condição do paciente.

A partir dos dados coletados ao longo do tempo é possível observar se a situação do paciente melhora ou piora. Os benefícios do Myo nessa aplicação são diversos uma vez que grande parte dos pacientes pós-AVC precisam ficar em repouso e o bracelete, por ser leve, compacto e sem fio se mostra adequado à situação.

Tanto os movimentos do braço são sensíveis ao Myo através de seu giroscópio, magnetômetro e o acelerômetro, quanto os sinais de eletromiografia do antebraço captados a partir dos oito sensores presentes na parte interior do Myo. Notas são dadas a partir das leituras realizadas pelo Myo e elas expressam as seguintes interpretações, como presente em (Hidayat, 2016):

Nota 0: Nenhum movimento detectado;

Nota 1: Apenas traço do movimento é captado;

Nota 2: Músculo tem movimento apenas se a resistência da gravidade for removida;

Nota 3: Força muscular reduzida tal que a articulação pode mover-se apenas contra a gravidade;

Nota 4: Força muscular reduzida mas contração muscular pode mover-se contra a resistência;

Nota 5: Contração muscular normal.

Com o auxílio do Myo foi possível perceber os diversos estados em que os pacientes se encontravam e melhorar a interpretação médica, assim como a evolução dos pacientes.





## 4 Identificação de Padrões em Sinais de sEMG

No presente capítulo serão apresentados assuntos de importante conhecimento para o desenvolvimento do trabalho proposto, desde a explicação de redes neurais, funções de ativação, arquiteturas e métodos para extração de características nos sinais de EMG, acelerômetro, giroscópio e quatérnios.

### 4.1 Redes Neurais Artificiais

Mecanismos envolvendo inteligência artificial foram idealizados em meados dos anos 50, desde que foi publicado o primeiro artigo sobre o tema. As aplicações possíveis vão desde processamento de imagens, controle de equipamentos diversos, automatização de dados do mercado financeiro, controle de carros e caminhões para direção autônoma em rodovias, processos médico-hospitalares facilitados, entre outras.

Redes neurais artificiais são modelos computacionais inspirados no sistema nervoso de seres vivos. Essas estruturas demonstram habilidade de adquirir e manter conhecimento e podem ser definidas como um sistema de unidades, representadas pelos neurônios artificiais, interligados por muitas interconexões, implementadas por vetores e matrizes de pesos sinápticos(SILVA *et al.*, 2017).

Existem parâmetros principais para a caracterização de redes neurais, entre elas podemos citar os presentes(SILVA *et al.*, 2017):

- Adaptação através da experiência;
- Capacidade de aprendizagem;
- Capacidade generalizada;
- Organização de dados;
- Tolerância a falhas;
- Armazenamento distribuído;
- Prototipação facilitada.

As redes neurais artificiais são estruturas criadas a partir do comportamento simplificado do que acontece nos neurônios do cérebro humano. Esses modelos foram propostos a partir do entendimento de como são gerados e propagados os impulsos elétricos de

um neurônio. O modelo de neurônio mais simples que inclui características biológicas foi proposto por McCulloch e Pitts em 1943 e ainda é o modelo mais usado em diferentes arquiteturas de redes neurais (SILVA *et al.*, 2017). Este modelo de neurônio artificial está representado na Figura 12.




Figura 12 – Modelo de neurônio artificial, existe um somatório de todas as entradas  $x_1$ ,  $x_2$ , ...,  $x_n$  multiplicadas por um peso específico  $w_1$ ,  $w_2$ , ...,  $w_n$ , sendo esse peso específico a relevância atribuída a cada entrada do neurônio,  $\theta$  é o limiar de ativação, usado para especificar o limite apropriado na saída do somador, há ainda o  $u$ , que desempenha o papel do potencial de ação que é o resultado produzido pela diferença entre o agregador de linear e do limite de ativação. O termo  $g$  representa o valor final de saída de um neurônio, pode ser ainda representar a entrada na sequência para outro neurônio. (SILVA *et al.*, 2017)

#### 4.1.1 Funções de Ativação Diferenciáveis

O comportamento dos neurônios que compõem a rede neural artificial pode ser modelado por meio de funções de ativação. Funções de ativação parcialmente diferenciáveis são funções com pontos cuja derivada de primeira ordem não existe (SILVA *et al.*, 2017). Algumas funções de ativação foram explanadas a seguir:

1. Função degrau: Resultado é um para o caso do potencial de ativação do neurônio ser maior ou igual a zero e será zero para quando o mesmo potencial de ativação for menor do que zero;
2. Função degrau bipolar ou função sinal: Resultado é um para o caso do potencial de ativação do neurônio ser maior que zero, resultado nulo para o potencial de ativação ser também nulo e o resultado é um negativo para o caso do potencial ser menor do que zero;
3. Função rampa simétrica: Os valores retornados pela função são iguais aos valores dos potenciais de ativação.

Funções de ativação completamente diferenciáveis são funções cuja derivada de primeira ordem existe para todos os pontos do seu domínio definido. As quatro funções dessa categoria as quais são as mais comumente utilizadas em redes neurais são as funções logarítmicas, tangente hiperbólica (Figura 13), função Gaussiana e função linear (SILVA *et al.*, 2017).




Figura 13 – Curva característica da tangente hiperbólica. O eixo das abscissas representa os valores  $X$  de entrada na função  $\tanh X$  e o eixo das ordenadas apresenta a resposta da função hiperbólica para cada entrada.

#### 4.1.2 Arquitetura das Redes Neurais

Redes neurais podem ser divididas em dois grandes grupos, a saber: redes de uma única camada e redes de múltiplas camadas. As redes multi-camadas, representada na Figura 14, são compostas por camadas de entrada, ou seja, os argumentos característicos escolhidos do sinal para se utilizar na classificação de um sinal, e de saída, que tem as inferências da rede quanto à classificação de um sinal, além de uma ou mais camadas ocultas. O número de neurônios em cada camada oculta pode variar conforme necessidade que dada rede precise para encontrar a sua melhor performance. Redes neurais possibilitam a resolução de diversos problemas de classificação de padrões. Entre os tipos de redes multi-camadas estão o *Multilayer Perceptron* (MLP) e o *Radial Basis Function* (RBF).

Existem camadas na arquitetura de redes neurais, entre elas podemos citar a camada de entrada, responsável por receber os sinais ou informações, normalmente normalizadas, advindas de algum componente ou aparelho externo. A segunda camada é a intermediária (ou oculta), capaz de extrair padrões durante o processamento dos sinais




Figura 14 – Representação de uma rede neural multi-camadas contendo uma camada de entrada com 3 neurônios, 2 camadas ocultas contendo 4 neurônios cada e uma camada de saída com um neurônio somente. (JOHNSON, 2017) adaptado.

analisados. A última camada a ser pontuada é a camada de saída, composta por neurônios que têm por objetivo apresentar um resultado.

A arquitetura de realimentação, ou arquitetura recorrente, é aquela em que a saída de um neurônio serve como entrada na mesma camada ou em uma camada anterior à saída, essa utilização, em alguns casos, pode melhorar o desempenho de uma rede neural ao ser utilizada (SILVA *et al.*, 2017). Algumas das mais importantes arquiteturas de realimentação estão a Hopfield e o Perceptron com realimentação entre neurônios de camadas diferentes.

## 4.2 Processo de Aprendizado

O processo de treinamento de uma rede neural consiste em aplicar os passos ordenados transformando pesos sinápticos e limiares de cada neurônio, de forma a generalizar as soluções produzidas para suas saídas (SILVA *et al.*, 2017). Em outras palavras, o mecanismo de aprendizado gerado internamente a uma rede neural é capaz de absorver valores consistentes e ponderar valores para cada sinal de entrada. A partir disso o sistema é capaz de gerar respostas em sua saída mapeada em relação à entrada anterior. O conjunto de passos usados para treinar uma rede é chamado de algoritmo de aprendizado. No presente estudo o algoritmo de treinamento utilizado foi o Levenberg-marquardt, algoritmo este que tem o método de treinamento mais rápido dos algoritmos utilizados.

Existem três subconjuntos dos sinais coletados, eles são chamados de conjunto de treino, conjunto de teste e conjunto de validação. O conjunto de treino tem, geralmente, entre 60% e 90% das amostras aleatórias coletadas e será utilizado essencialmente para

o aprendizado da rede neural quanto à classificação dos sinais, O conjunto de teste é utilizado para se averiguar a classificação da rede e a validação é o último resultado quanto à precisão de uma rede neural em obter acertos.

### 4.2.1 Aprendizado Supervisionado

O aprendizado supervisionado consiste em avaliar as amostras de treino com suas correspondentes respostas de saída, isso requer dados de entrada e de saída. A partir disso as estruturas neurais serão criadas e será formada o que se entende por hipótese do sistema de aprendizado. Os pesos sinápticos e limiares da rede neural são continuamente ajustados durante a aplicação e os erros vão sendo minimizados durante o processo de aprendizado. O processo é tido como bem sucedido quando o aprendizado apresenta características aceitáveis de saída em relação à entrada.

### 4.2.2 Aprendizado Não-supervisionado

Diferentemente do aprendizado supervisionado, a aplicação não supervisionada não requer qualquer conhecimento das saídas desejadas. O algoritmo encontra padrões a partir de características presentes nas amostras, identificando subconjuntos de amostras, ajustando pesos sinápticos e limiares de forma a refletir em sua própria rede.

## 4.3 Wavelets

Este capítulo apresenta uma breve introdução à teoria de wavelets sob a ótica da análise de sinais. A todo momento estamos nos deparando com sinais, por exemplo: sinais sísmicos, sinais de rádio, imagens, entre outros. Esses sinais, para seu processamento e análise, contam com uma série de ferramentas, onde talvez a mais conhecida seja a transformada de Fourier, que representa um sinal através de funções senoidais de diferentes frequências. Através da transformada de Fourier, um sinal representado no domínio do tempo é transformado para o domínio da frequência.

A transformada wavelet apresenta-se como uma ferramenta alternativa para o processamento de sinais, mudando o paradigma de representação dos mesmos, ao utilizar funções base de suporte compacto (em vez das senoidais de Fourier) para transformar um sinal para o espaço de tempo-escala.

No caso de processamento de imagens, um dos pontos fortes da transformada wavelet vem do fato que com uma quantidade mínima de valores (em um escala menor da imagem) é possível representar a imagem toda sem perdas relativas na maioria dos casos. Esses valores podem ser aproveitados na montagem do vetor de característica para representação de uma imagem.

As wavelets estão sendo utilizadas em inúmeras áreas, por exemplo; na mecânica de fluídos, computação numérica, análise de imagens, processamento de sinais, sistemas de controle, fenômenos biológicos, medicina e psicologia. No futuro próximo, espera-se que a análise de wavelets seja uma ferramenta de análise e visualização como a transformada de Fourier.

### 4.3.1 Transformada de Fourier

Uma das técnicas mais populares de processamento de sinais é a transformada de Fourier, que tem como objetivo transformar um sinal (função) do domínio de espaço para o domínio de frequência.

A função responsável pela transformação é dada por:

$$F(u) = \int f(t)e^{-j\omega t} dt, \quad (4.1)$$

em que a equação corresponde à transformada de Fourier de um sinal contínuo  $f(t)$ , a qual apresenta algumas deficiências, entre elas o fato de que esta transformação não relaciona os intervalos de tempo com as frequências. Isso ocorre porque a transformada está baseada na integração de toda a função para cálculo de cada frequência. Esse problema não aconteceria se o sinal não mudasse durante o tempo (sinais estacionários), mas acontece que muitos sinais contém características não estacionárias ou transitórias.

Para solucionar o problema citado, Dennis Gabor no ano de 1964 adaptou a transformada de Fourier para analisar somente uma parte do sinal em um tempo e introduziu a transformada por janelas de Fourier (WFT, do inglês, Windowed Fourier Transform). Nesta aplicação, uma janela de observação é deslocada no domínio do tempo e a transformada de Fourier da porção visível do sinal é calculada para cada posição da janela. Considerando  $j(t)$  a função que cumpre o papel de janela, pode-se definir a transformada por janelas de Fourier de um sinal contínuo  $f(t)$  como:

$$F(u, b) = \int j(t - b)f[t]e^{-i2\pi ut} dt, \quad (4.2)$$

o problema que surge então é que uma vez definido o tamanho para a janela, esta permanece constante para todas as frequências. Alguns sinais então, que precisem de um enfoque mais flexível, podem necessitar de uma janela que mude de tamanho para detectar o conteúdo local da frequência (DAUBECHIES, 1990).

### 4.3.2 Transformada Wavelet

Transformada *wavelet* é uma técnica que janelas com regiões de dimensão variável, onde as *wavelets*, diferentemente de Fourier, tem como base uma função de duração limitada, ou seja, de suporte compacto, que é uma propriedade na qual seu domínio é

diferente de zero em uma extensão finita e igual a zero em todo o resto. Isto torna interessante a utilização das *wavelets* no caso específico da análise de imagens, pois as mudanças de regiões ou bordas podem ser detectadas mais facilmente.

A definição de uma transformada *wavelet* considerando um sinal contínuo é dado por:

$$F(a, b) = \int f(t)\psi_{a,b}(t)dt, \quad (4.3)$$

em que os parâmetros  $a$  e  $b$  variam continuamente em  $R$ , sendo que as funções  $\psi_{a,b}$  são denominadas *wavelets* e definidas da seguinte forma:

$$\psi_{a,b} = \frac{1}{\sqrt{a}}\psi\left(\frac{t-b}{a}\right). \quad (4.4)$$

A transformada *wavelet* para sinais contínuos é definida como:

$$F_{m,n}(a, b) = a_0^{-\frac{m}{2}} \int f(t)\psi(a_0^{-m}t - nb_0). \quad (4.5)$$

É possível notar que o comportamento desta função está baseada em dilatações e translações a partir de uma *wavelet* mãe  $\psi$ , em que a *wavelet* mãe deve satisfazer a propriedade:

$$\int \psi(t)dt = 0. \quad (4.6)$$

Observando a Equação 4.3 é possível perceber que a transformada *wavelet* depende de dois parâmetros  $a$  e  $b$ , que correspondem às informações de escala e tempo respectivamente (DAUBECHIES, 1990).

## 4.4 Matriz de Co-ocorrência de Níveis de Cinza (GLCM)

A matriz de co-ocorrência de níveis de cinza (GLCM, do inglês, *Gray-level co-occurrence matrix*) é um método de análise de textura que melhora os detalhes de um sinal fornecendo uma interpretação numérica do mesmo. É uma técnica que emprega experimentos estatísticos realizados sobre a ocorrência de um certo nível de cinza.

Também, pode ser baseado na ocorrência repetida da configuração de alguns níveis de cinza na textura, ou seja, na presença de texturas finas a variação é caracterizada por ser rápida e em texturas ásperas a variação tem um comportamento lento. O GLCM de uma região de interesse é calculado usando o vetor de deslocamento  $d$  definido raio e ângulos de rotação ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$ ), como mostrado na Figura 15.

O método GLCM, a ser detalhado mais adiante, consiste em uma matriz que representa a quantidade de co-ocorrências entre certos valores de níveis de cinza em uma

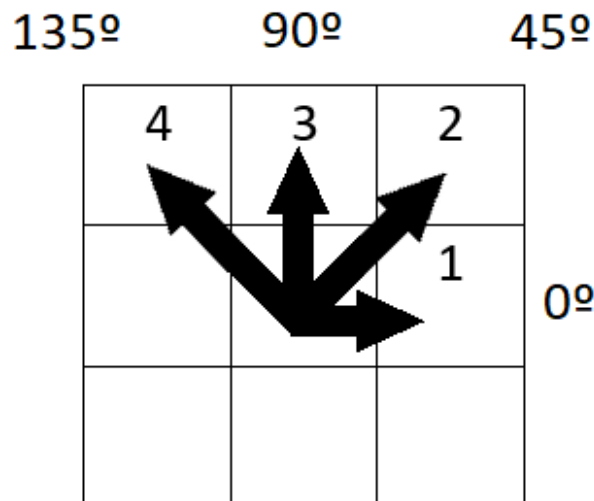


Figura 15 – Direções de referência adotadas no GLCM.

imagem, dado um relacionamento espacial entre os píxeis (uma distância e um ângulo). Foi uma das primeiras técnicas de extração de características de segunda ordem desenvolvidas e serviu como base para o surgimento de muitas outras.

A GLCM (Grey-Level Co-occurrence Matrix) é uma técnica utilizada dentro da área de análise de texturas, que foi desenvolvida na década de 70 pelo pesquisador Robert M. Haralick (HARALICK; SHANMUGAN; DINSTEIN, 1973). É um método estatístico para extração de características que usa estatísticas de segunda ordem, pois analisa as co-ocorrências existentes entre pares de píxeis, ou seja, ela não analisa cada pixel individualmente mas sim, conjuntos de píxeis relacionados através de algum padrão.

Uma GLCM é uma matriz sempre quadrada que mantém informações das intensidades relativas dos píxeis em uma dada imagem. Ela calcula as probabilidades de co-ocorrências entre dois níveis de cinza  $i$  e  $j$ , dada uma certa distância  $s$  (também conhecida como pps ou pixel pair spacing) e uma orientação  $\theta$ , que pode assumir os valores de  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$  (BARALDI; PARMIGGIANI, 1995). Existe uma matriz de co-ocorrência para cada relacionamento espacial possível (combinações da distância  $s$  e da orientação  $\theta$ ). Todas as informações sobre a textura de uma imagem vão estar contidas nessa matriz. Um elemento da matriz GLCM contém uma probabilidade, ou seja, a frequência com que um dado pixel de nível  $i$  está na vizinhança de um pixel de nível  $j$ . Um cálculo simples para essa probabilidade seria o número de vezes com que tal co-ocorrência acontece dividido pela número total de combinações possíveis (HARALICK; SHANMUGAN; DINSTEIN, 1973). É possível estabelecer o relacionamento entre três ou mais píxeis, só que não é muito eficiente em termos computacionais, portanto, essa abordagem não é utilizada na prática.

Um exemplo de uma matriz GLCM obtida a partir dos píxeis de uma imagem pode



ser visto na Figura 16. Observe que o relacionamento estabelecido é (1,1), ou seja, um pixel adjacente horizontalmente a uma distância unitária. O elemento na linha 1 e coluna 1 da matriz GLCM tem o valor 1, o que indica que existe apenas uma única situação na imagem onde um pixel de nível de intensidade 1 é adjacente horizontalmente a um outro pixel de nível de intensidade 1. O elemento na linha 1 e coluna 2 da matriz GLCM tem o valor 2, o que indica que existem duas ocorrências na imagem onde um pixel de nível de intensidade 1 é adjacente horizontalmente a um pixel de nível de intensidade 2. Esse processo é repetido até que a matriz GLCM esteja completa.

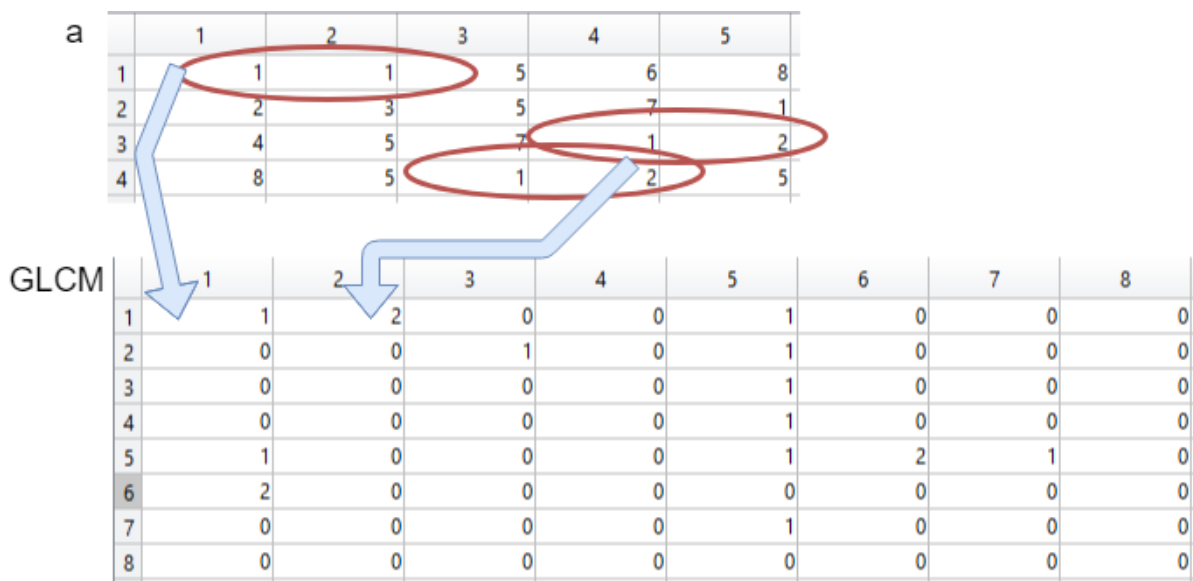


Figura 16 – Processo de construção de uma matriz GLCM a partir de uma imagem. A matriz de cima representa as intensidades nos níveis de cinza do sinal original, na debaixo é possível observar a matriz resultante após os cálculos de co-ocorrência dos níveis de cinza.

Uma análise computacional da obtenção da matriz GLCM a partir da representação matricial da imagem mostra que o relacionamento escolhido (offsets) não interfere na complexidade do algoritmo. Para um dado offset, a imagem deve ser percorrida pixel a pixel para verificar se algum pixel possui o relacionamento estabelecido e incrementar essa quantidade na matriz GLCM. Logo, se imagem possui  $N$  píxeis, a complexidade será  $O(N)$ , independente do offset que foi escolhido.

Assim, uma outra forma de entender um elemento da matriz GLCM, é pensar nele como a quantidade de vezes que um pixel de nível  $i$  aparece a uma distância  $s$  e a uma orientação  $\theta$  de um pixel de nível  $j$ . Tanto o  $i$  quanto o  $j$  variam de zero até a quantidade de níveis de cinza, também chamada de quantização. Essas quantidades devem ser transformadas em probabilidades antes de se fazer o cálculo das características. O processo de transformar uma matriz GLCM em uma aproximação de uma tabela de

probabilidades é chamado de normalização (HARALICK; SHANMUGAN; DINSTEN, 1973).

Este processo é apenas uma aproximação, pois uma verdadeira probabilidade só trabalha com valores contínuos e os níveis de cinza são valores inteiros, portanto discretos.

É importante notar que a imagem a partir da qual será obtida a matriz GLCM, deve ser primeiramente convertida para uma imagem em nível de cinza. Uma imagem em nível de cinza, geralmente é composta por tons de cinza, variando entre o preto com a menor intensidade e o branco com a maior intensidade. O tamanho da matriz GLCM depende da quantidade de níveis de cinza. Ela possui um número de linhas e um número de colunas igual a quantidade de níveis de cinza.

Em relação a quantidade de níveis de cinza, isso varia muito de uma imagem para outra. Uma imagem binária possui dois níveis de cinza (0 e 1). Uma imagem em níveis de cinza, pode possuir quaisquer quantidade de níveis de cinza variando de 0 a 255. Geralmente são utilizados 4 ou 8 níveis de cinza, mas esse valor pode variar dependendo da situação.

O algoritmo para geração de uma matriz GLCM a partir de uma imagem em nível de cinza, faz uma varredura na matriz que representa a imagem e determina, para cada combinação de níveis  $i$  e  $j$ , a quantidade de co-ocorrências que existem entre eles, usando o relacionamento espacial definido como base.

Uma vez que a matriz é preenchida com base em uma imagem já convertida para níveis de cinza, a técnica aplica estatísticas ao longo de toda a matriz para calcular as características mais relevantes da textura. Uma das abordagens é percorrer a matriz da esquerda para a direita e de cima para baixo, analisando elemento por elemento, independente do elemento ser zero ou não. Para cada um dos elementos, é aplicado estatísticas que gerarão as características de interesse.

Para definir a direção, o GLCM baseia-se no ângulo, como mostrado na Figura 16 (que representa a formação do GLCM com quatro tons de cinza e distância igual a 1 pixel). Saindo do centro (o) para o pixel 1, o ângulo é igual a  $0^\circ$  e a direção é horizontal; para o pixel 2 o ângulo é igual a  $45^\circ$  e a direção é diagonal direita; para o pixel 3 o ângulo é igual a  $90^\circ$  e a direção é vertical; e para o pixel 4 o ângulo é igual a  $135^\circ$ , a direção é diagonal esquerda (MUKHERJEE, 2001). A direção define como ocorre a ordem da leitura da imagem original, ou seja a direção do pixel vizinho a ser analisado.

No GLCM as características de textura é obtida por um conjunto de medições retiradas a partir da matriz normalizada.

Abaixo a descrição de algumas equações utilizadas para definir essas medições (LIU; YU; GAO, 2015):

- Correlação: é a medida da dependência linear dos tons de cinza entre os pixel de uma posição específica. píxeis próximos possuem uma correlação mais próxima que píxeis distantes entre si.

$$R = \sum_{ij} \frac{(i - \mu_i)(j - \mu_j)glcm(i, j)}{\sigma_i \sigma_j} \quad (4.7)$$

- Contraste: mede o valor da diferença entre o valor da intensidade do píxeis vizinhos.

$$C = \sum_{ij} |i - j|^2 glcm(i, j) \quad (4.8)$$

- Homogeneidade local: é a medição que proporciona a similaridade local da imagem, utilizando pesos que retorna baixos valores para imagens não homogênea, quando i diferente de j.

$$H = \sum_{ij} \frac{glcm(i, j)}{1 + |i - j|} \quad (4.9)$$

- Energia: Soma do quadrado de cada elemento presente na Matriz de co-ocorrência de níveis de cinza.

$$E = \sum_{ij} glcm(i, j)^2 \quad (4.10)$$



## 5 Metodologia

No presente capítulo será explicada a metodologia adotada no trabalho para aquisição dos sinais de eletromiografia, acelerômetro, giroscópio e quatérnios no antebraço de cinco pessoas para o primeiro teste e nove pessoas para o segundo teste, todas elas destros e sem histórico de miopatias. Também serão mostrados pontos importantes das padronizações adotadas para futuro aumento do banco de dados.

### 5.1 Dispositivos e Softwares

Os dispositivos físicos necessários para se realizar a captação de sinais são somente o *Myo Armband* e um computador com conexão USB. Para conectar o Myo ao computador usa-se um adaptador USB para transmissão de dados por Bluetooth.

Após as etapas de conexão do dispositivo desenvolveu-se um código para gerar gráficos dos sinais provenientes do Myo, primeiramente sinais adquiridos e guardados para cada um de seus oito sensores

Após testes diversos foi necessário um código para visualização dos sinais captados em tempo real, ou seja, com atraso pouco perceptível entre a aquisição do sinal e a geração do gráfico.

### 5.2 Protocolo de Aquisição dos Sinais para o Primeiro Teste

Seguindo as etapas de elaboração do projeto, criou-se um banco de dados com sinais de eletromiografia correspondentes aos 5 movimentos que são reconhecidos pelo software comercial do equipamento, a saber:

1. Gesto 1: Mão à direita
2. Gesto 2: Duplo clique
3. Gesto 3: Mão fechada
4. Gesto 4: Mão aberta
5. Gesto 5: Mão à esquerda

Para a elaboração do banco de dados foi adotado um padrão a ser seguido para prevenir erros durante a execução e para que possa ser reproduzido futuramente ao ser

preciso aumentar o número de sinais do banco de dados. Após testes preliminares, decidi-se que o tempo ideal para o procedimento era de 10 segundos de captação de cada gesto, sendo feito para 5 pessoas diferentes, destras e com 3 repetições para cada movimento, com observação do gráfico resultante para validação de que a captação ocorreu corretamente. A sequência do procedimento está a seguir:

1. Com o primeiro sujeito sentado em uma cadeira com braços, encostar o cotovelo do braço direito no braço da cadeira;
2. Colocar o dispositivo Myo Armband com o sensor principal acima do músculo braquio-radial, não distante do cotovelo, como mostrado na Figura 17;
3. Preparar o sistema para aquisição dos sinais;
4. O sujeito espera 2 segundos com o braço relaxado para começar a realizar o movimento, em seguida faz o movimento em aproximadamente 3 segundos e espera o restante do tempo acabar com o braço relaxado novamente;
5. Gera-se então o gráfico dos sinais adquiridos no movimento realizado e analisa-se visualmente se a coleta do sinal não teve demasiado ruído ou se houve movimento abrupto capaz de danificar o sinal e se o braço estava realmente relaxado antes e depois do movimento;
6. Salvar as amostras coletadas;
7. Para cada um dos 5 gestos, repete-se a captação até se ter 3 do mesmo gesto de cada pessoa;



Figura 17 – Myo posicionado no braço direito

Os sinais captados nos sujeitos representam um protocolo útil para futuros entendimentos de todo o processo realizado, pois para repetir e continuar a captação as mesmas práticas já utilizadas devem continuar sendo aplicadas.

A Tabela 2 apresenta os dados antropométricos dos voluntários que participaram da aquisição dos sinais.

Tabela 2 – Características dos sujeitos participantes da extração de sinais de 5 gestos diferentes e 3 repetições para cada gesto durante a fase de aquisição do primeiro teste.

Sujeitos	Idade (anos)	Sexo	Altura (m)	Massa (kg)
1	23	M	1.87	82
2	48	F	1.62	65
3	22	F	1.72	62
4	57	M	1.70	75
5	20	F	1.60	63

É importante salientar que nenhuma das pessoas da pesquisa apresentam histórico de miopatias, seja no braço ou em outras regiões do corpo, pois, caso houvesse, poderia interferir nos resultados esperados e distorcer o aprendizado da rede neural.

As características médias dos entrevistados foram as seguintes:

- Idade: 34 anos;
- Sexo: 40% de homens e 60% de mulheres;
- Altura: 1,7 m;
- Massa: 69,4 kg

### 5.3 Extração de Características dos Sinais

Para se distinguir qual movimento o sujeito está realizando é necessário criar uma base de dados com algumas características de cada movimento, as características observadas durante essa etapa de projeto foram a de potência e energia de cada sinal de sensor, para os gestos 2 e 3, ou seja, duplo clique e mão fechada, respectivamente. Funções separadas foram criadas para calcular a potência e a energia. A seguir estão as equações para cálculo da energia de um sinal (5.1) e potência média de um sinal (5.2).

$$E = \sum_{n=-\infty}^{\infty} |x(n)|^2 \quad (5.1)$$

$$P = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{n=-N}^N |x(n)|^2 \quad (5.2)$$

Para cada sinal mioelétrico existente no banco de dados com 10 segundos cada, foi gerado o gráfico para observação do que fora captado pelos sensores. Após avaliar a zona em que o sinal do gesto se encontra cada um dos sinais foi seccionado para apresentar apenas 3 segundos (600 amostras) e os sinais foram salvos. O valor de 3 segundos foi obtido a partir da análise de tempo de execução de cada gesto e então foi definido que a maior janela de tempo para um gesto sucede no máximo em 3 segundos.

Para implementar a rede neural foi utilizada uma segunda segmentação do sinal, cada um foi dividido em 3 partes de 200 amostras cada e para cada um desses novos sinais foram calculadas as energias e potências resultantes e adicionados os valores eram adicionados em uma mesma linha. Para o calculo seguinte os 6 valores então eram escalonados em uma nova linha e assim sucessivamente até que todos os sinais tivessem as características obtidas. As características apresentadas serviram então de entrada nas tentativas de obtenção da melhor rede neural.

## 5.4 Rede Neural para Identificação de Padrões

A rede neural utilizada testa a melhor performance para valores entre 10 e 20 neurônios, entretanto, o número de neurônios será limitado caso seja suficiente uma quantidade reduzida de neurônios para que a rede consiga a melhor performance durante as tentativas de treinamento. A função de ativação para a aplicação foi a tangente hiperbólica. Ao se iniciar a rede neural escolhe aleatoriamente neurônios para serem testados, dessa forma a rede melhora seu desempenho e tende a não ficar viciada.

## 5.5 Metodologia Aplicada para o Segundo Teste

Para adquirir os sinais para a análise completa dos gestos foi necessário um grupo mais de pessoas. Nove sujeitos no total atuaram na extração de sinais com o bracelete Myo Armband.

### 5.5.1 Classes de movimentos

Os seguintes gestos foram os escolhidos para compor as 9 classes de movimentos:

- Gesto 1: Mão fechada
- Gesto 2: Mão aberta
- Gesto 3: Mão à direita
- Gesto 4: Mão à esquerda



- Gesto 5: Duplo clique
- Gesto 6: Flexão do braço
- Gesto 7: Extensão do braço
- Gesto 8: Pronação do braço
- Gesto 9: Supinação do braço

Nas Figuras 18 a 26 é possível observar cada uma dos movimentos supracitados:



Figura 18 – Gesto 1 ou mais especificamente: mão fechada, sendo realizado por um dos sujeitos. Vista lateral.



Figura 19 – Gesto 2 ou mais especificamente: mão aberta, sendo realizado por um dos sujeitos. Vista lateral.



Figura 20 – Gesto 3 ou mais especificamente: mão à direita, sendo realizado por um dos sujeitos. Vista superior.



Figura 21 – Gesto 4 ou mais especificamente: mão à esquerda, sendo realizado por um dos sujeitos. Vista superior.



Figura 22 – Gesto 5 ou mais especificamente: duplo clique (polegar e dedo médio tocando-se duas vezes em curto intervalo de tempo), sendo realizado por um dos sujeitos. Vista lateral.



Figura 23 – Gesto 6 ou mais especificamente: flexão do braço, sendo realizado por um dos sujeitos. Vista lateral.



Figura 24 – Gesto 7 ou mais especificamente: extensão do braço, sendo realizado por um dos sujeitos. Vista lateral.



Figura 25 – Gesto 8 ou mais especificamente: pronação do braço, sendo realizado por um dos sujeitos. Vista lateral.



Figura 26 – Gesto 9 ou mais especificamente: supinação do braço, sendo realizado por um dos sujeitos. Vista lateral.

### 5.5.2 O Método

Para analisar as diferenças entre diferentes características, como proposto no trabalho, foi necessário aumentar a quantidade de sujeitos em que os sinais eram coletados assim como a quantidade de repetições para cada gesto.

Portanto, nove pessoas tiveram sinais extraídos, como mostrado na Tabela 3, sendo nove classes e quatro repetições para cada gesto. Do ponto de vista de sinais extraídos, EMG, giroscópio, acelerômetro, magnetômetro e quatérnios foram salvos a ciclo de captação de sinais.

Para realizar a captação dos sinais nesta etapa os principais tópicos foram os seguintes:

- Colocar a pessoa sentada de maneira confortável;
- Colocar o bracelete Myo no braço direito de maneira que a referência do sensor sempre fique na mesma posição;
- Realizar quatro leituras de cada um dos cinco primeiros gestos, a saber: mão fechada, mão aberta, mão à direita, mão à esquerda e clique;
- Salvar todos os sinais acima citados;
- Realizar a aquisição dos gestos 6 a 9, a saber: extensão, flexão, pronação e supinação;
- Salvar os sinais dos movimentos restantes.

Após as etapas de aquisição de sinais foi necessário criar um programa de computador para seccionar o sinal de várias leituras em arquivos diferentes, cada um com três segundos, tempo observado ser o máximo do maior gesto completo.

O programa então tem como entrada os sinais com muitas repetições, esses sinais são seccionados em três segundos cada, e então como saída são salvos arquivos com 600 amostras para cada sinais de EMG e 150 amostras para sinais de acelerômetro, do giroscópio, do magnetômetro e dos quatérnios. Isso acontece porque a frequência de aquisição dos sinais de EMG é de 200 Hz, enquanto a frequência dos demais sinais captados no bracelete é de 50 Hz.

Tendo os sinais seccionados e salvos, foi contabilizado um total de 1.620 sinais, sendo 324 de cada um dos tipos de sinais coletados (EMG, acelerômetro, magnetômetro, giroscópio e quatérnio).

As características médias dos entrevistados foram as seguintes:

- Idade: 29,1 anos;

Tabela 3 – Características dos sujeitos participantes da extração de sinais de 9 gestos diferentes e 4 repetições para cada gesto durante a fase de aquisição do segundo teste.

<b>Sujeitos</b>	<b>Idade (anos)</b>	<b>Sexo</b>	<b>Altura (m)</b>	<b>Massa (kg)</b>
1	49	F	1.61	63
2	24	M	1.74	70
3	20	F	1.60	67
4	22	F	1.72	63
5	57	M	1.76	74
6	23	M	1.79	81
7	21	F	1.60	70
8	23	F	1.78	67
9	23	M	1.87	83

- Sexo: 44,4% de homens e 55,5% de mulheres;
- Altura: 1,71 m;
- Massa: 70,88 kg

Assim como nas primeiras aquisições de sinais, os sujeitos alvos nesta etapa de aquisição de sinais são todos destros e não apresentam miopatias musculares ou quaisquer síndromes motoras que possam comprometer capacidade do antebraço em realizar os corretos movimentos supracitados.



## 6 Resultados

Neste capítulo serão apresentados os resultados obtidos para o primeiro e segundo teste, entre os resultados estão taxas de acerto, melhores redes e gráficos para avaliação do erro associado a cada cenário.

### 6.1 Resultados do Primeiro Teste

Nesta seção serão apresentados os resultados do processo de estimação dos movimentos das mãos para duas classes, duplo clique e mão fechada, após as etapas de aquisição de uma base de dados, testes, treino e validação com a rede neural, também serão mostrados gráficos avaliando os resultados obtidos.

#### 6.1.1 Gráfico de Aquisição dos Sinais

Para exibir as amostras captadas ao longo do tempo foi desenvolvido o código em que o gráfico tem a capacidade de plotar amostras e deslocar o eixo horizontal de forma que as novas amostras sendo coletadas surjam do lado direito e desloquem-se para o lado esquerdo. Assim, é possível perceber visualmente que os dados estão sendo plotados ao longo do tempo e os sinais aparecem da forma como na Fig. 27 a seguir:




Figura 27 – Captura de tela de um gráfico em tempo real com todos os sinais de EMG dos oito sensores presentes no bracelete Myo em um dos sujeitos em que o sinal fora coletado, no eixo das abscissas está o tempo de execução e na ordenadas os valores que cada um dos sinais atinge ao longo do tempo.

Também é possível separar o gráfico conforme cada um dos oito sinais dos eletrodos, dessa forma podemos exibir o formato de ondas geradas para o mesmo movimento da Fig. 26.

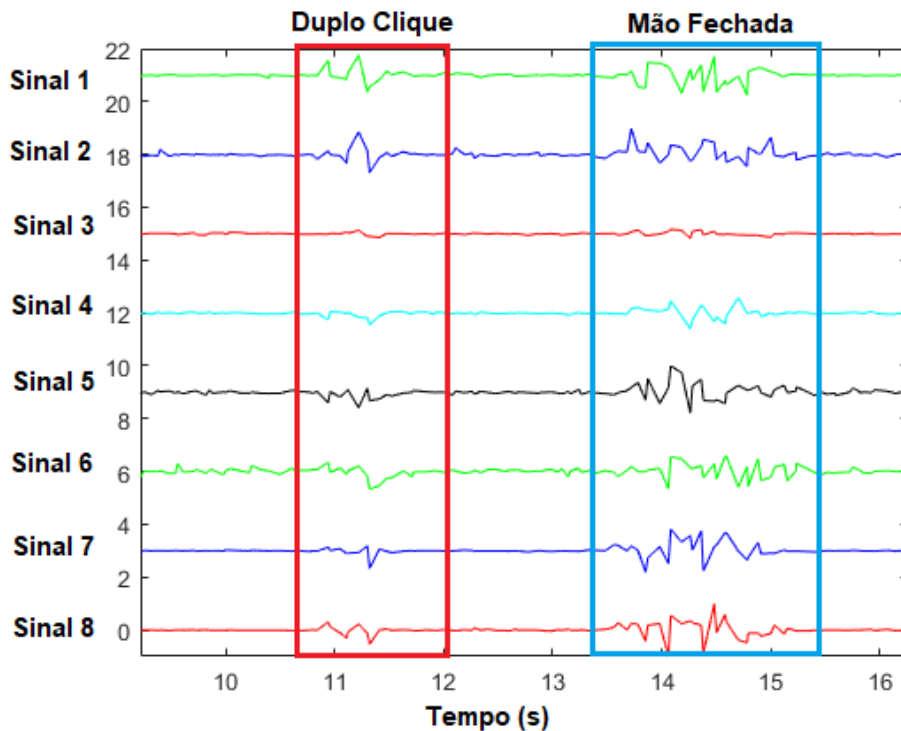


Figura 28 – Captura de tela de um gráfico em tempo real com os sinais separados, no eixo das abscissas está o tempo de execução e na ordenadas os valores que cada um dos sinais atinge ao longo do tempo. Cada um dos sinais se referem ao que fora captado no sensor do Myo de mesma numeração.

### 6.1.2 Resultados da Rede Neural

O mapeamento dos padrões teve as características presentes na Figura 29, sendo o esperado presente no eixo X e o previsto no eixo Y.

Também foram traçadas curvas para cada uma das etapas presentes:

1. Treino
2. Teste
3. Validação
4. Todas as curvas






Figura 29 – Mapeamento dos padrões dos movimentos

Dessa forma é possível notar a curva em que há 100% de acerto, que no caso é a que percorre a diagonal, e as curvas coloridas são as presentes como resultado da rede neural, como representado na Figura 30.

Sabendo que a rede neural foi programada para aplicar nos testes entre 10 e 20 neurônios, o melhor resultado foi representado na Figura 31. Observamos que 15 neurônios foi o suficiente para ter um nível de 96.6% de acerto. Nota-se que as curvas decrescem com o tempo de processamento, o que significa que o erro está sendo reduzido. Quando nota-se que o erro diminuiu dessa forma, pode ser que hajam problemas na rede porque pode acontecer do sistema ficar sobreajustado, no entanto, pela curva de validação nota-se que a queda cessa, nesse momento percebe-se que o ajuste excessivo foi superado e o teste continua sendo válido.

A tabela 4 mostra os resultados obtidos na rede que gerou a melhor performance na classificação para os 2 gestos, a saber: mão fechada e clique.

Tabela 4 – Resultados da melhor rede para a classificação de 2 classes de gestos.

<b>Taxa de acerto</b>	96.6%
<b>Quantidade de neurônios</b>	15

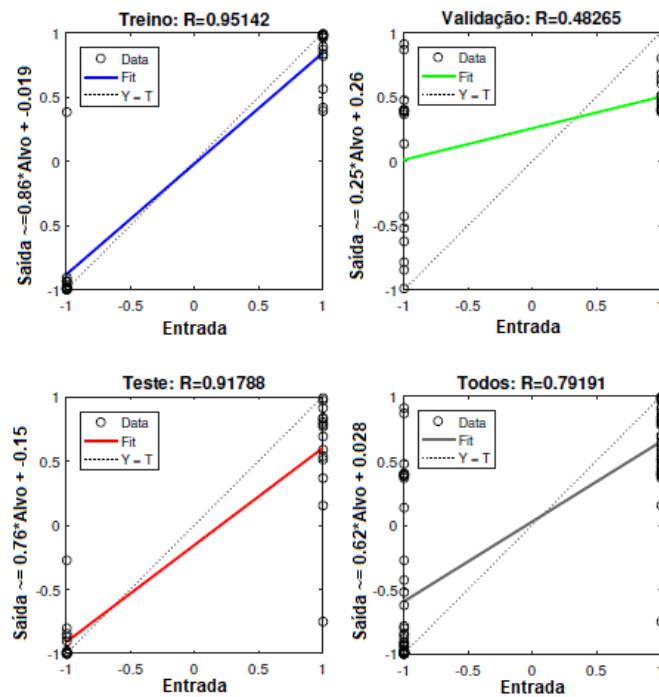


Figura 30 – Curvas de regressão para as etapas de treino, validação, teste e todas

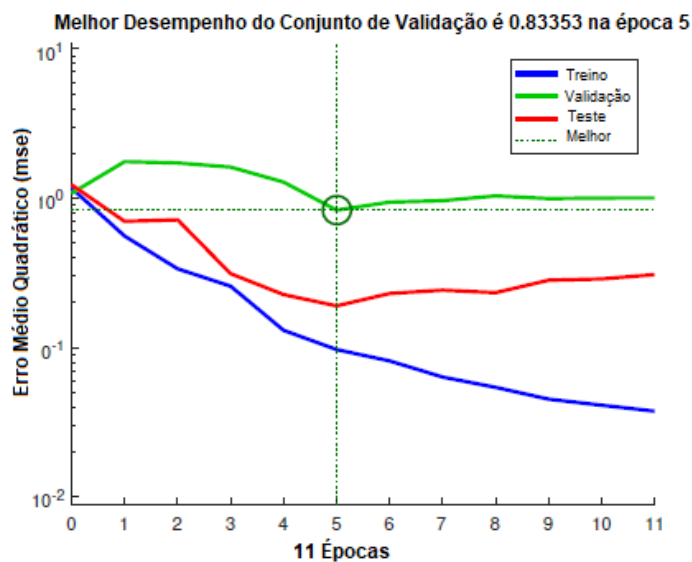


Figura 31 – Gráfico de evolução da rede neural. As linhas de melhor desempenho indicam o ponto em que o treinamento foi concluído. Neste ponto o erro do conjunto de validação é o menor sem que tenha vício. No eixo das ordenadas é possível ver o erro quadrático médio sobre o conjunto de dados de treino, validação e teste. No eixo das abscissas nota-se a quantidade de épocas durante a evolução da rede.

## 6.2 Resultados do Segundo Teste

A partir dos métodos propostos foram gerados cenários para comparar a utilização das diferentes características na classificação de gestos com uma rede neural artificial. Foram exibidas as taxas de acerto que cada rede geral ao validar a classificação dos sinais e peculiaridades da melhor rede como quantidade de neurônios, quantidade de tentativas até atingir o menor valor de erro, quantidade de sinais utilizados em cada rede e as características adotadas em cada um dos modelos propostos.

### 6.2.1 Treinamento das redes neurais

Para avaliar os melhores resultados e poder classificar as melhores características em uma rede neural foram utilizados os sinais de EMG, acelerômetro, giroscópio e quaternio, sendo um total de 1.296 sinais. Antes dos sinais serem entrada na rede neural foram utilizadas técnicas de cálculo da potência e energia para alguns e wavelets e GLCM para outros.

### 6.2.2 Cenário 1: Diferenciação de 5 classes com características de EMG e cálculo da energia e da potência

Para o primeiro cenário foram selecionados os cinco primeiros gestos, a saber: mão fechada, mão aberta, mão à direita, mão à esquerda e clique. Estes são os cinco gestos já reconhecidos de fábrica pelo software do Myo e que neste proposição seria possível adotar uma rede neural para repetir o reconhecimento dos movimentos feitos com a mão.

A sequência do treinamento utilizado no cenário 1 podem ser vistos a seguir:

1. Como entrada da rede neural foram calculados a energia e a potência de cada um dos sinais de EMG, seccionado em 3 partes de 200 amostras cada, portanto a camada de entrada tem 6 neurônios;
2. O tamanho de saída de rede é 5;
3. O método de treinamento utilizado na rede neural é o Levenberg-Marquardt;
4. Foi utilizada uma camada oculta de 1 a 50 neurônios
5. O limite de 1000 épocas foi adotado no experimento;
6. 20 tentativas são realizadas em cada neurônio;
7. Os dados são divididos de forma que 70% seja para treinamento, 15% para validação e 15% para teste;

8. Ao conseguir o melhor desempenho de teste a rede é salva e os passos continuam até que se obtenha uma rede ainda melhor.

Como mostrado na tabela 5, com 25 neurônios e na 2ª tentativa de treinamento a rede obteve a melhor performance, e a taxa de acertos ao validar as métricas do que a rede classifica e o alvo foi de 96.3%.

Tabela 5 – Resultados da melhor rede do Cenário 1.

Taxa de acerto	96.3%
Quantidade de neurônios	25

O gráfico da evolução da rede neural do cenário 1 pode ser observado na Figura 32:




Figura 32 – Gráfico de evolução da rede neural do cenário 1. As linhas de melhor desempenho indicam o ponto em que o treinamento foi concluído. Neste ponto o erro do conjunto de validação é o menor sem que tenha vício. No eixo das ordenadas é possível ver o erro quadrático médio sobre o conjunto de dados de treino, validação e teste. No eixo das abscissas nota-se a quantidade de épocas durante a evolução da rede.

### 6.2.3 Cenário 2: Diferenciação de 5 classes com características de EMG e IMU e utilização de wavelets e GLCM

No cenário 2 foi proposto observar as taxas de acerto, e busca pela melhor rede para 5 classes, as mesmas do cenário 1, e utilização somente dos sinais de EMG, acelerômetro,

giroscópio e quatérnios, porém, nessa segunda abordagem utilizou-se wavelets em cada sinal sem seccioná-lo e após ter o resultado das wavelets foi calculada a matriz de co-ocorrência de níveis de cinza.

As seguintes características foram extraídas de cada um dos sinais após ter a matriz de co-ocorrência:

- Contraste;
- Correlação;
- Homogeneidade;
- Energia.

A sequência do treinamento utilizado no cenário 2 podem ser vistos a seguir:

1. Como entrada da rede neural foram calculadas as transformadas wavelets de cada canal do sinal e para cada sensor e os valores foram colocados em uma mesma matriz;
2. Da matriz resultante das wavelets foi gerada a matriz de co-ocorrência em níveis de cinza e foram extraídos os valores de contraste, correlação, homogeneidade e energia de cada um dos sinais resultantes da matriz de co-ocorrência de níveis de cinza;
3. A matriz contendo as características de contraste, correlação, homogeneidade e energia para todos os sinais é utilizada como entrada no teste de obtenção da melhor rede neural;
4. A camada de entrada, portanto, tem 32 neurônios;
5. O tamanho de saída de rede é de 9;
6. O método de treinamento utilizado na rede neural é o Levenberg-Marquardt;
7. Foi utilizada uma camada oculta de 1 a 50 neurônios
8. O limite de 1000 épocas foi adotado no experimento;
9. 20 tentativas são realizadas em cada neurônio;
10. Os dados são divididos de forma que 70% seja para treinamento, 15% para validação e 15% para teste;
11. Ao conseguir o melhor desempenho de teste a rede é salva e os passos continuam até que se obtenha uma rede ainda melhor.

Como mostrado na tabela 6, com 7 neurônios e na 16<sup>o</sup> tentativa de treinamento a rede obteve a melhor performance, e o taxa de acertos ao validar as métricas do que a rede classifica e o alvo foi de 48.1%.

Tabela 6 – Resultados da melhor rede do Cenário 2.

Taxa de acerto	48.1%
Quantidade de neurônios	7

O gráfico da evolução da rede neural do cenário 1 pode ser observado na Figura 33:




Figura 33 – Gráfico de evolução da rede neural do cenário 2. As linhas de melhor desempenho indicam o ponto em que o treinamento foi concluído. Neste ponto o erro do conjunto de validação é o menor sem que tenha vício. No eixo das ordenadas é possível ver o erro quadrático médio sobre o conjunto de dados de treino, validação e teste. No eixo das abscissas nota-se a quantidade de épocas durante a evolução da rede.

#### 6.2.4 Cenário 3: Diferenciação de 9 classes com características de EMG e IMU e utilização de GLCM

Para ter uma visão geral de como funciona a rede neural com cada uma das características utilizadas foi feita uma rede com entradas para as 9 classes de movimentos,

utilizando todos os sinais de eletromiografia, acelerômetro, giroscópio e quatérnios. Esses sinais ainda foram tratados com wavelets e a matriz de co-ocorrência em níveis de cinza foi gerada. A quantidade de sinais utilizada nesta aplicação foi maior entre os cenários estudados, um total de 1.296. Buscou-se a melhor, ou seja, que obtêm a maior quantidade de acertos da classificação em comparação com os alvos.

Da mesma forma que no cenário 2, as seguintes características foram extraídas de cada um dos sinais após ter a matriz de co-ocorrência:

- Contraste;
- Correlação;
- Homogeneidade;
- Energia.

A sequência do treinamento utilizado no cenário 3 podem ser vistos a seguir:

1. Como entrada da rede neural foram calculadas as transformadas wavelets de cada canal do sinal e para cada sensor e os valores foram colocados em uma mesma matriz;
2. Da matriz resultante das wavelets foi gerada a matriz de co-ocorrência em níveis de cinza e foram extraídos os valores de contraste, correlação, homogeneidade e energia de cada um dos sinais resultantes da matriz de co-ocorrência de níveis de cinza;
3. A matriz contendo as características de contraste, correlação, homogeneidade e energia para todos os sinais é utilizada como entrada no teste de obtenção da melhor rede neural;
4. A camada de entrada, portanto, tem 32 neurônios;
5. O tamanho de saída de rede é de 9;
6. O método de treinamento utilizado na rede neural é o Levenberg-Marquardt;
7. Foi utilizada uma camada oculta de 1 a 50 neurônios
8. O limite de 1000 épocas foi adotado no experimento;
9. 20 tentativas são realizadas em cada neurônio;
10. Os dados são divididos de forma que 70% seja para treinamento, 15% para validação e 15% para teste;

11. Ao conseguir o melhor desempenho de teste a rede é salva e os passos continuam até que se obtenha uma rede ainda melhor.

A tabela 7 evidencia que, com 4 neurônios e na 15<sup>o</sup> tentativa de treinamento, a rede obteve a melhor performance, e o taxa de acertos ao validar as métricas do que a rede classifica e o alvo foi de 61.2%.

Tabela 7 – Resultados da melhor rede do Cenário 3.

<b>Taxa de acerto</b>	61.2%
<b>Quantidade de neurônios</b>	4

O gráfico da evolução da rede neural do cenário 3 pode ser observado na Figura 34:

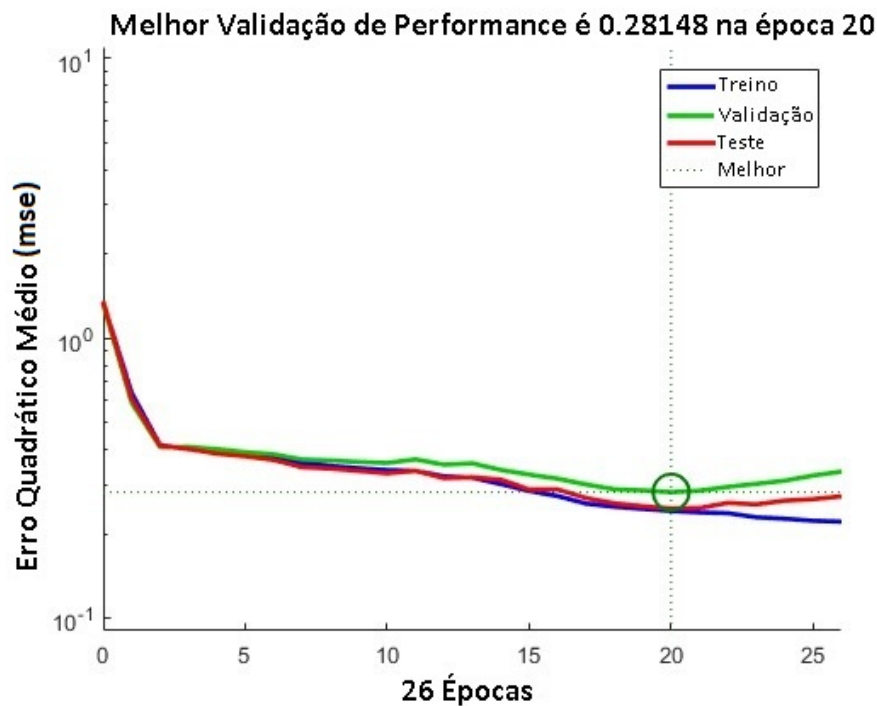


Figura 34 – Gráfico de evolução da rede neural do cenário 3. As linhas de melhor desempenho indicam o ponto em que o treinamento foi concluído. Neste ponto o erro do conjunto de validação é o menor sem que tenha vício. No eixo das ordenadas é possível ver o erro quadrático médio sobre o conjunto de dados de treino, validação e teste. No eixo das abscissas nota-se a quantidade de épocas durante a evolução da rede.



## 7 Conclusões

Haja visto as possibilidades de se utilizar um dispositivo vestível para realizar funções como o controle de drones, próteses médicas, braços robóticos, foi realizado o estudo quanto à estimação de gestos específicos das mãos e dos braços se utilizando o bracelete Myo.

O aparelho dispõe de sensores inerciais como acelerômetro, giroscópio, magnetômetro e quatérnios assim como sensores mioelétricos espalhados por toda sua extensão de circunferência. Para testar o reconhecimento de padrões foi gerada uma base de dados coletando os gestos em 9 sujeitos. Uma rede neural foi utilizada e para cada sinal, características como potência, energia, wavelet, matriz de co-ocorrência em níveis de cinza, homogeneidade, contraste, correlação e energia, sendo esta em relação à co-ocorrência em níveis de cinza.

Os sinais obtidos foram classificados a partir de redes neurais, com diferentes abordagens como classificação de 2 classes e uso somente sinais de EMG, classificação de 5 classes com uso de EMG, calculando os valores de energia e potência para cada sinal; classificação de 5 classes com o uso do sinal de EMG e dos sinais provenientes do IMU com cálculo da GLCM e extração dos valores de contraste, energia, correlação e homogeneidade; e por último, a classificação de 9 classes com sinais de EMG e da IMU, se utilizando novamente da GLCM e extração das características de contraste, energia, correlação e homogeneidade.

Os resultados obtidos a partir da metodologia utilizada foram consistentes e mostram que algumas características tornam a classificação das redes neurais mais exata, como a utilização dos sinais de EMG, também é possível notar que para experimentos de classificação para 2 ou 5 classes a rede é capaz de se arranjar de forma a obter taxas de acerto próximos de 100%, porém, ao se utilizar GLCM e wavelets, especificamente neste trabalho, a rede neural não rede neural com a quantidade de neurônios testados não foi capaz de estabelecer uma taxa de acerto que possibilite o controle de um dispositivo.

Além dos resultados obtidos a partir do método proposto, a principal contribuição pessoal foi no aperfeiçoamento de técnicas de processamento de sinais, aprendizado e controle de redes neurais artificiais utilizando softwares profissionais para a classificação e também para exercício da persistência na vida de engenharia.

Portanto, este projeto foi importante no estudo de aprofundamento de processamento de sinais biológicos, especificamente para o bracelete Myo, para aplicar o que fora estudado em teoria, assim como fomento para futuros trabalhos de continuação para controle de dispositivos que tenham alguma demanda e que se encaixe com a funcionalidade

vestível e compacta do bracelete Myo.

Ainda se faz necessário o aprofundamento na matéria para que novos comparativos sejam feitos entre as diferentes escolhas de características para dados sinais advindos do bracelete Myo para validar a funcionalidade da estimação de gestos para mais classes, principalmente para movimentos que não podem ser definidos exclusivamente com a utilização do EMG, assim como para melhorar a performance de acertos da classificação de redes neurais em relação aos alvos a serem obtidos.

# Referências

- ABDUO, M.; GALSTER, M. Myo gesture control armband for medical applications. University of Canterbury, 2015. Citado 2 vezes nas páginas 23 e 51.
- ABREU, J. G.; TEIXEIRA, J. M.; FIGUEIREDO, L. S.; TEICHRIEB, V. Evaluating sign language recognition using the myo armband. Universidade Federal de Pernambuco, 2016. Citado 2 vezes nas páginas 23 e 50.
- ACAR; SHKEL. *MEMS Vibratory Rate Gyroscopes, Structural Approaches to Improve Robustness*. [S.l.], 2009. 99-108 p. Citado na página 43.
- ARIEF, Z.; SULISTIJONO, I. A.; ARDIANSYAH, R. A. Comparison of five time series emg features extractions using myo armband. Politeknik Elektronika Negeri Surabaya (PENS), 2015. Citado 2 vezes nas páginas 23 e 52.
- BARALDI; PARMIGGIANI. *An In-vestigation of the Textural Characteristics As-sociated with Gray Level Co-occurrence Ma-trix Statistical Parameters*. [S.l.], 1995. 293-304 p. Citado na página 62.
- BARBERO; MERLETTI; RAINOLDI. *Atlas of muscle innervation*. Rio de Janeiro, Brasil, 2012. 145 p. Citado 4 vezes nas páginas 15, 33, 34 e 35.
- BEEBY; ENSELL; KRAFT; WHITE. *MEMS mechanical sensors*. Artech House, 2004. Citado 2 vezes nas páginas 19 e 42.
- DAUBECHIES. *Ten Lectures on Wavelets*. Philadelphia, 1990. Citado 2 vezes nas páginas 60 e 61.
- FARINA; MERLETTI. *Electromyography, Surface, physiology, engineering and applications*. [S.l.], 2016. 593 p. Citado 4 vezes nas páginas 15, 36, 38 e 39.
- FIGUEIREDO; GAFANIZ; LOPES; PEREIRA. “Aplicações de acelerómetros”. *IAS - Instrumentação de Aquisição de Sinais*. [S.l.], 2007. Citado na página 42.
- FUX. *Development of a planar low cost Inertial Measurement Unit for UAVs and MAVs*. [S.l.], 2008. 110 p. Citado na página 42.
- HARALICK; SHANMUGAN; DINSTEN. *Textural Features for Image Classification*. [S.l.], 1973. 610-621 p. Citado 2 vezes nas páginas 62 e 64.
- HIDAYAT, A. A.; ARIEF, Z.; YUNIARTI, H. Lovett scaling with myo armband for monitoring finger muscles therapy of post-stroke people. Polytechnic Institute of Surabaya, 2016. Citado 2 vezes nas páginas 24 e 53.
- JOHNSON, J. *Representação de uma rede neural multi-camadas*. 2017. Disponível em: <<http://cs231n.github.io/neural-networks-1/>>. Acesso em: 01.12.2017. Citado 2 vezes nas páginas 16 e 58.
- KIM h. J.; LEE, Y. S.; KIM, D. Arm motion estimation algorithm using myo armband. Kyung Hee University, 2017. Citado 2 vezes nas páginas 23 e 49.

- LIU; YU; GAO. *A novel mrf-based image segmentation approach*. [S.l.], 2015. 150-157 p. Citado na página 64.
- MAENAKA. *Vibrating Beam Accelerometer with Hard Suspension Beams*. [S.l.], 2007. 1207-1210 p. Citado na página 43.
- MERLETTI. *Eletromyography*. [S.l.], 2004. 505 p. Citado 3 vezes nas páginas 15, 34 e 35.
- MOURA, F. S.; SORIANO, D. C. Integrating myo armband for the control of myoelectric upper limb prosthesis. Universidade Federal do ABC, 2016. Citado 2 vezes nas páginas 23 e 51.
- MUKHERJEE. *Retrieval of Multimedia Information Using Content-Based Image Retrieval (CBIR) Techniques*. [S.l.], 2001. Citado na página 64.
- RIPKA. *Magnetic Sensors and Magnetometers*. [S.l.], 2009. 99-108 p. Citado na página 45.
- SILVA; SPATTI; FLAUZINO; LIBONI; ALVES. *Artificial Neural Networks, A Pratical Course*. [S.l.], 2017. 309 p. Citado 5 vezes nas páginas 16, 55, 56, 57 e 58.
- SORNMO; LAGUNA. *Bioelectrical Signal Processing in Cardiac and Neurological Applications*. [S.l.], 2015. 685 p. Citado 4 vezes nas páginas 15, 35, 36 e 37.
- SUNDSTROM, M. *Representação das posições dos sensores no Myo*. 2015. Disponível em: <<https://www.linkedin.com/pulse/rock-paper-scissors-reviewing-myo-gesture-control-matt-sundstrom>>. Acesso em: 06.12.2017. Citado 2 vezes nas páginas 15 e 48.
- YADI; AYAZI; NAJAFI. *Micromachined inertial sensors*. [S.l.], 1998. 1640-1659 p. Citado na página 41.