

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
DEPARTAMENTO ACADÊMICO DE ELETRÔNICA  
MESTRADO EM ENGENHARIA ELÉTRICA**

**JOSÉ JAIR ALVES MENDES JÚNIOR**

**DESENVOLVIMENTO DE UMA ARMBAND PARA CAPTURA DE  
SINAIS ELETROMIOGRÁFICOS PARA RECONHECIMENTO DE  
MOVIMENTOS**

**DISSERTAÇÃO**

**PONTA GROSSA**

**2016**

**JOSÉ JAIR ALVES MENDES JÚNIOR**

**DESENVOLVIMENTO DE UMA ARMBAND PARA CAPTURA DE  
SINAIS ELETROMIOGRÁFICOS PARA RECONHECIMENTO DE  
MOVIMENTOS**

Dissertação apresentada como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica, do Departamento Acadêmico de Eletrônica da Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Dr. Sergio Luiz Stevan Jr.  
Co-orientador: Prof. Dr. Sérgio Okida

**PONTA GROSSA**

**2016**

Ficha catalográfica elaborada pelo Departamento de Biblioteca  
da Universidade Tecnológica Federal do Paraná, Campus Ponta Grossa  
n.03/17

M538 Mendes Júnior, José Jair Alves

Desenvolvimento de uma armband para captura de sinais eletromiográficos  
para reconhecimento de movimentos / José Jair Alves Mendes Júnior. -- 2017.  
113 f. : il. ; 30 cm.

Orientador: Prof. Dr. Sergio Luiz Stevan Jr.

Coorientador: Prof. Dr. Sérgio Okida

Dissertação (Mestrado em Engenharia Elétrica) - Programa de Pós-Graduação  
em Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Ponta  
Grossa, 2017.

1. Eletromiografia. 2. Redes neurais (Neurobiologia). 3. Movimentos. 4.  
Engenharia elétrica. I. Stevan Jr., Sergio Luiz. II. Okida, Sérgio. III. Universidade  
Tecnológica Federal do Paraná. IV. Título.

CDD 621.3



---

## FOLHA DE APROVAÇÃO

Título de Dissertação Nº /2016

**DESENVOLVIMENTO DE UMA ARMBAND PARA CAPTURA DE SINAIS  
ELETROMIOGRÁFICOS PARA RECONHECIMENTO DE MOVIMENTOS**  
por

JOSÉ JAIR ALVES MENDES JÚNIOR

Esta dissertação foi apresentada às 14 do dia 12/12/2016 como requisito parcial para a obtenção do título de MESTRE EM ENGENHARIA ELÉTRICA, com área de concentração em Controle e Processamento de Energia, linha de pesquisa em Instrumentação e Controle do Programa de Pós-Graduação em Engenharia Elétrica. O candidato foi argüido pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

Prof. Dr. Alexandre Balbinot (UFRGS)

Prof. Dr. Sérgio Francisco Pichorim  
(UTFPR)

Prof. Dr. Abraham Elias Ortega Paredes  
(UTFPR)

Prof. Dr. Sérgio Luiz Stevan Jr (UTFPR) -  
*Orientador*

Prof. Dr. Sérgio Okida (UTFPR)  
*Co-orientador*

Prof. Dr. Claudinor Bitencourt(UTFPR)  
Coordenador do PPGE

A FOLHA DE APROVAÇÃO ASSINADA ENCONTRA-SE NO DEPARTAMENTO DE  
REGISTROS ACADÊMICOS DA UTFPR –CÂMPUS PONTA GROSSA

## **AGRADECIMENTOS**

À Deus, Criador de tudo e de todas as coisas, Senhor da inteligência e do conhecimento, que nos ama e faz as coisas mais inesperadas a todos. Por toda a sua paciência com esse humilde pecador. Agradeço também a Nossa Mãe que por muitas vezes me segurou por um fio.

Agradeço pelos meus pais, José e Maria, por todo o esforço, pela paciência, pelo ânimo e pelo entendimento de muitas horas a fio de trabalho e longe de casa.

Agradeço a minhas irmãs, meus sobrinhos e meu cunhado por tantas vezes compreenderem o meu afastamento de momentos de diversão para a conclusão desta etapa.

Ao meu orientador, Prof. Sérgio Stevan, agradeço por toda a ajuda, conhecimento, histórias e momentos compartilhados. Ao meu co-orientador, Prof. Sérgio Okida, pelas dúvidas sanadas e incentivo a cada conversa.

Aos meu caros amigos e colegas, especialmente aos que fazem parte da equipe CIEBE, aos quais compartilhamos e unimos momentos como se sentíssemos em casa. Aos colegas do curso de mestrado, de corredores e de aulas, por toda a cooperação durante esta etapa.

Aos meus irmãos do Guerreiros de Cristo, que me aguentaram por esses anos, carregando as histórias e partilhando os momentos da vida.

E por fim, a todos os que ajudaram em algo para o desenvolvimento deste trabalho, sem vocês, isso não seria possível.

## RESUMO

MENDES JÚNIOR, José Jair Alves. **Desenvolvimento de uma armband para captura de sinais eletromiográficos para reconhecimento de movimentos.** 2016. 117f. Dissertação (Mestrado em Pós-Graduação em Engenharia Elétrica) - Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2016.

Esta dissertação apresenta o desenvolvimento de um sistema em forma de *armband* para a captura de sinais de eletromiográficos de superfície para o reconhecimento de movimentos do braço. São apresentadas todas as suas etapas de projeto, desde a construção física, projeto de circuitos, sistema de aquisição, processamento e classificação por meio de Redes Neurais Artificiais. Foi construído um bracelete contendo oito canais para a captação do sinal de eletromiografia e um sistema auxiliar (giroscópio) de referência foi utilizado para indicar o instante em que o braço foi movimentado. Foram adquiridos dados dos grupos musculares do bíceps e do tríceps. Por meio da fusão de dados de sensores, os sinais foram processados por meio de rotinas no *software* LabVIEW™. Após a extração de características do sinal, as amostras foram encaminhadas para uma Rede Neural Multi-Layer Perceptron para a classificação dos movimentos de flexão e extensão do braço. A mesma *armband* foi inserida na região do antebraço e os sinais de eletromiografia foram comparados com os sinais obtidos pelo dispositivo comercial Myo™. O sistema apresentou como resultado altas taxas de classificação, acima de 95% e os sinais obtidos na região do antebraço apresentaram semelhanças com os obtidos pelo dispositivo comercial.

**Palavras-chave:** Eletromiografia. *Armband*. Redes Neurais Artificiais. Classificação. Reconhecimento de Movimentos.

## ABSTRACT

MENDES JÚNIOR, José Jair Alves. **Development of an armband to capture of electromyography signals for movement recognition.** 2016. 117f. Masters Thesis (Master on Post-Graduation Program in Electrical Engineering) – Federal University of Technology, Paraná. Ponta Grossa, 2016.

This master thesis presents the development of an armband system to capture of superficial electromyography signals to arm movement recognition. All project steps, since the physical building, project of the circuits, acquisition system, processing and classification by Artificial Neural Networks are presented. An armband with eight channel to capture the electromyography signal was constructed and an auxiliary system (gyroscope) was used to indicate the instant when the arm was moved. The muscle acquired groups were the biceps and triceps. By sensor data fusion, the signals were processed by LabVIEW™ routines. After the signal characteristic extraction, the samples were forwarded to a Multi-Layer Perceptron Neural Network to movement classification of arm flexion and extension. The same armband was inserted on the forearm and the electromyography signals were compared with the signals obtained by the commercial device Myo™. The system presented, as results, high classification rates, above of 95% and the obtained signals on the region of forearm showed similarities with the obtained ones by commercial device.

**Keywords:** Electromyography. Armband. Artificial Neural Networks. Classification. Movement Recognition.

## LISTA DE FIGURAS

Figura 1 – Histórico das principais interfaces desenvolvidas com sEMG.....	13
Figura 2 – a) Primeiro sistema <i>armband</i> com sEMG publicado, b) <i>armband</i> usada para reconhecimento de gestos da mão, em destaque os eletrodos costurados no bracelete, c) <i>armband</i> com uso de fusão de sensores inerciais, d) protótipo de <i>armband</i> para identificação de gestos de motoristas e e) <i>armband</i> comercial Myo™. ....	15
Figura 3 – Representação dos elementos básicos do controle motor.....	19
Figura 4 – Estrutura de um músculo esquelético.....	21
Figura 5 – Potencial de Ação típico.....	22
Figura 6 – Representação do processo de propagação de PA e registro de PAUMs por meio da superfície da pele.....	23
Figura 7 – Músculos do braço nas vistas a) anterior e b) posterior.....	25
Figura 8 – Músculos do antebraço nas vistas a) anterior superficial e b) posterior superficial.....	26
Figura 9 – Etapas de aquisição e pré-processamento do sinal de sEMG.....	27
Figura 10 – Modos de configuração dos eletrodos: a) monopolar e b) bipolar.....	29
Figura 11 – Exemplo do sinal de sEMG, nos domínios a) do tempo e b) da frequência.....	30
Figura 12 – Esquemático de um amplificador de instrumentação, em destaque a) seus estágios de entrada e b) seu amplificador diferencial.....	31
Figura 13 – Especificações gerais da banda esperada de frequências dos filtros de sEMG.....	36
Figura 14 – Representação e alimentação das partes isoladas e não-isoladas dos sistemas de condicionamento do sinal de sEMG.....	38
Figura 15 – Classificação e estágios dos sistemas que utilizam o EMG para controle. a) sem reconhecimento de padrões; e b) com reconhecimento de padrões.....	40
Figura 16 – Métodos de técnica de janelamento da segmentação dos dados, em que a) representa a abordagem adjacente e b) a abordagem sobreposta. $S_n$ representa cada segmento extraído e $t$ o atraso do processamento.....	41
Figura 17 – Representação dos níveis de fusão de sensores.....	48
Figura 18 – Modelo de neurônio artificial.....	52
Figura 19 – Arquitetura de uma MLP.....	55
Figura 20 – Erros de validação e de treinamento em relação ao número de treinamentos.....	58
Figura 21 – Esquemático do primeiro protótipo do conjunto de eletrodos.....	63
Figura 22 – Dimensão a) dos eletrodos antes e depois do ajuste e b) dos contatos de pressão e sua fixação nos eletrodos.....	64
Figura 23 – Visão inferior da <i>armband</i> , em destaque a) com os eletrodos e b) os contatos de pressão.....	64
Figura 24 – Bloco funcional interno de um INA 128P.....	65
Figura 25 – Placa do circuito de amplificação.....	66



Figura 26 –Filtros <i>anti-aliasing</i> propostos, sendo a) seu esquemático e valores comerciais e b) na placa.....	67
Figura 27 – Vista superior do sistema de <i>armband</i> , placa de aquisição e circuitos de condicionamento. ....	68
Figura 28 – Ligação com o Arduino Mega com o giroscópio.....	70
Figura 29 – Sistema <i>armband</i> e giroscópio com indicação de seus eixos e direção dos movimentos de flexão e extensão. ....	71
Figura 30 – Fluxograma do diagrama de blocos do VI de aquisição em LabVIEW™	72
Figura 31 – Fluxograma do VI de condicionamento e processamento no Diagrama de Blocos em LabVIEW™.....	73
Figura 32 – Esquemático de operações para extração de características. ....	74
Figura 33 – Circuito de simulação com o INA128 no <i>software</i> Orcad/PSPICE .....	77
Figura 34 – Resposta do ganho do circuito de amplificação utilizando o INA 128, sendo apresentados seus valores calculados, simulados e reais. ....	78
Figura 35 – Esquemático de simulação do circuito do filtro <i>anti-aliasing</i> .....	79
Figura 36 – Resposta em frequência da magnitude do filtro <i>anti-aliasing</i> , contendo os valores simulados e reais.....	79
Figura 37 – Painel frontal do sistema de aquisição de sinais.....	80
Figura 38 – Dados adquiridos do giroscópio (Giro, em °/s) e dos oito canais de sEMG C <sub>1</sub> a C <sub>8</sub> (em mV), com a identificação dos movimentos: (A), início da flexão; (B), início da extensão; e (C), final do movimento.....	81
Figura 39 – Painel de monitoramento da rotina de segmentação e extração de características do banco de dados.....	82
Figura 40 – Gráfico do erro x épocas de um dos treinamentos da MLP. ....	83
Figura 41 –Diagrama de blocos do sistema de aquisição, estando destacadas: a) suas configurações iniciais, b) aquisição dos dados, c) rotina de salvamento, d) temporização e orientação ao indivíduo e e) configurações finais. ....	98
Figura 42 – SubVI de separação dos dados do giroscópio, sendo a) seu símbolo e b) seu diagrama de blocos. ....	101
Figura 43 – Parte inicial do diagrama de blocos do sistema de segmentação e extração de características, em destaque, as rotinas de a) abertura do arquivo de aquisição, b) condicionamento dos dados, c) segmentação e extração de características. ....	104
Figura 44 – Parte final do diagrama de blocos do sistema de segmentação e extração de características, em destaque, as rotinas de d) laços de repetição e gravação dos dados. ....	105
Figura 45 – SubVI de ajuste dos <i>array</i> do giroscópio, sendo a) seu símbolo e b) seu diagrama de blocos.....	107
Figura 46 – SubVI de condicionamento do sinal de sEMG, sendo a) seu símbolo e b) seu digrama de blocos. ....	108
Figura 47 – SubVI de segmentação e extração de características, sendo a) seu símbolo e b) seu diagrama de blocos.....	109

## LISTA DE TABELAS

Tabela 1 – Principais características que podem ser extraídas do sinal de EMG, suas equações e considerações. ....	43
Tabela 2 - Principais características da MLP construída com MAV .....	76
Tabela 3 – Exemplo de Características Extraídas, exemplificando em seis amostras os valores de MAV, RMS, Variância e IEMG dos Canais C <sub>1</sub> e C <sub>2</sub> .....	83
Tabela 4 – Resultados da média dos acertos e seu desvio padrão entre as etapas de treinamento e de teste da MLP para as quatro características. ....	84

## LISTA DE SIGLAS

AC-DC	Corrente Alternada – Corrente Contínua
AD	Analógico – Digital
Ca	Cálcio
CC-CC	Corrente Contínua - Corrente Contínua
CI	Circuito Integrado
CMRR	<i>Common Mode Rejection Ratio</i> (Taxa de Rejeição de Modo Comum)
DOF	<i>Degree of Freedom</i> (Grau de Liberdade)
dps	<i>degrees per second</i> (graus de liberdade)
ECG	Eletrocardiografia
EEG	Eletroencefalografia
EMG	Eletromiografia
FIR	<i>Finite Impulse Response</i> (Resposta Finita ao Impulso)
I <sub>2</sub> C	<i>Inter-Integrated Circuit</i> (Circuito Inter-Integrado)
IEMG	Integral de EMG
IHM	Interface Homem Máquina
IIR	<i>Infinite Impulse Response</i> (Resposta Infinita ao Impulso)
IMU	<i>Inertial Measurement Unit</i> (Unidade de Medição Inercial)
K	Potássio
LDA	<i>Linear Discriminant Analysis</i> (Análise dos Discriminantes Lineares)
MAV	<i>Mean Absolute Value</i> (Média do Valor Absoluto)
MEMS	<i>Micro-Electro-Mechanical System</i> (Sistema Micro Eletro-Mecânico)
MLP	<i>Multi-Layer Perceptron</i> (Perceptron de Múltiplas Camadas)
Na	Sódio
PA	Potencial de Ação
PAUM	Potencial de Ação de Unidade Motora
RBF	Rede de Base Radial
RMS	<i>Root Mean Square</i> (Raiz Quadrática Média)
RNA	Rede Neural Artificial
sEMG	Eletromiografia de Superfície
TDANN	<i>Time-Delayed Artificial Neural Network</i> (Rede Neural Artificial Atrasada no Tempo)
UM	Unidade Motora
VI	<i>Virtual Instrument</i> (Instrumento Virtual)

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>12</b>
1.1 SISTEMAS MULTICANAIS E <i>ARMBANDS</i> .....	13
1.2 OBJETIVOS.....	17
1.2.1 Objetivo Geral.....	17
1.2.2 Objetivos Específicos.....	17
1.3 JUSTIFICATIVA.....	17
1.4 ORGANIZAÇÃO DA DISSERTAÇÃO .....	18
<b>2 REVISÃO BIBLIOGRÁFICA</b> .....	<b>19</b>
2.1 ORIGEM DO SINAL ELETROMIOGRÁFICO .....	19
2.1.1 Unidade Motora .....	20
2.2 PRINCIPAIS CONCEITOS DE ANATOMIA MUSCULAR DOS MEMBROS SUPERIORES.....	24
2.3 INSTRUMENTAÇÃO DO SINAL ELETROMIOGRÁFICO .....	25
2.3.1 Eletrodos.....	25
2.3.2 Característica dos sinais de sEMG .....	30
2.3.3 Amplificação.....	31
2.3.4 Filtragem.....	35
2.3.5 Taxa de amostragem e conversão AD.....	37
2.3.6 Isolação e Proteção .....	37
2.4 CARACTERÍSTICAS DOS SISTEMAS DE COMANDO POR EMG .....	38
2.4.1 Segmentação dos dados .....	40
2.4.2 Extração de características.....	42
2.4.3 Sistemas sem reconhecimento de Padrões (Análise de Limiar e Máquinas de Estados Finitos) .....	44
2.4.4 Classificação (Reconhecimento de Padrões) .....	45
2.4.5 Sistema de Controle .....	46
2.5 FUNDAMENTOS SOBRE FUSÃO DE SENSORES.....	47
2.5.1 Sensores Inerciais .....	49
2.6 REDES NEURAIS ARTIFICIAIS .....	50
2.6.1 Perceptron de Múltiplas Camadas (MLP) .....	53
2.7 CONCLUSÃO DO CAPÍTULO .....	58
<b>3 METODOLOGIA</b> .....	<b>59</b>
<b>4 DESENVOLVIMENTO</b> .....	<b>62</b>
4.1 CONCEPÇÃO FÍSICA .....	62
4.1.1 Amplificador de Instrumentação.....	65
4.1.2 Filtro anti-aliasing.....	66
4.1.3 Sistema de aquisição.....	67
4.1.4 Giroscópio (L3G4200D).....	69
4.2 SOFTWARE DE AQUISIÇÃO .....	71

4.3 SISTEMA DE CONDICIONAMENTO E PROCESSAMENTO .....	72
4.4 CLASSIFICAÇÃO POR REDES NEURAIS (MLP).....	74
4.5 CONCLUSÃO DE CAPÍTULO .....	76
<b>5 RESULTADOS .....</b>	<b>77</b>
5.1 RESULTADOS OBTIDOS DO SISTEMA FÍSICO.....	77
5.1.1 Amplificação.....	77
5.1.2 Filtro <i>anti-aliasing</i> .....	78
5.2 RESULTADOS OBTIDOS COM O SISTEMA DE AQUISIÇÃO .....	80
5.3 RESULTADOS OBTIDOS COM O SISTEMA DE TRATAMENTO E EXTRAÇÃO DE CARACTERÍSTICAS .....	81
5.4 RESULTADOS OBTIDOS DA CLASSIFICAÇÃO POR REDES NEURAIS ARTIFICIAIS.....	83
5.5 DISCUSSÃO .....	84
<b>6 CONSIDERAÇÕES FINAIS.....</b>	<b>86</b>
<b>REFERÊNCIAS.....</b>	<b>88</b>
<b>APÊNDICE A - Instrumento Virtual de aquisição dos dados de sEMG e do giroscópio em LabVIEW .....</b>	<b>97</b>
<b>APÊNDICE B - Instrumento Virtual de condicionamento e processamento do sinal de sEMG em LabVIEW.....</b>	<b>103</b>
<b>APÊNDICE C - Código de implementação da MLP no MATLAB® .....</b>	<b>111</b>

## 1 INTRODUÇÃO


Dentre os ramos da Engenharia Biomédica, uma das áreas que mais se destaca é o desenvolvimento de sistemas com interfaces entre homem-máquina (IHM) comandados por meio de sinais provenientes do corpo humano. Notoriamente, há uma grande possibilidade de dispositivos que podem ser comandados, como por exemplo próteses, órteses, exoesqueletos, robôs, sistemas eletromecânicos, entre outros (ANDREONI *et al.*, 2007; BROCK *et al.*, 2010; HAKONEN; PIITULAINEN; VISALA, 2015).

Um dos bio-sinais provenientes do ser humano que é amplamente usado para essas aplicações é o sinal elétrico decorrente da ativação muscular, que pode ser coletado na superfície da pele. Estes sinais são obtidos por uma técnica nomeada Eletromiografia (EMG). Conceitualmente, a EMG pode ser definida como a técnica de detecção, aquisição, análise, processamento, estudo e uso do sinal elétrico proveniente de contrações musculares (DE LUCA, 2006; KAMEN; GABRIEL, 2015). Essa técnica foi primeiramente utilizada para fins de pesquisa e diagnóstico; entretanto, o avanço da tecnologia permitiu que a mesma pudesse ser usada em: sistemas de controle artificial de movimentos e controle de próteses; sistemas de reabilitação; sistemas de estimulação elétrica funcional; aplicações nas áreas de *biofeedback*<sup>1</sup>; e aprofundamento de questões clínicas e cinesiológicas (CRAM, 2003; CRISWELL, 2011; DE LUCA, 2006; HENNENBERG, 2000).

A Figura 1 ilustra uma linha temporal com os principais usos de interfaces com sinais de eletromiografia (HAKONEN; PIITULAINEN; VISALA, 2015). O primeiro registro de uma interface em forma de prótese utilizando EMG data do ano de 1948, pelo trabalho de Reiter, o qual utilizava um atuador operado por um músculo (SAUTER *et al.*, 1985). Posteriormente, em 1960, por meio dos trabalhos de Tomovic e Kobrinski foi apresentada a primeira prótese comercial utilizando eletromiografia de superfície (sEMG, do inglês, *superficial EMG*) (DE LUCA, 2006). Baseada em controle por análise de limiar (*threshold*), a prótese continha apenas um grau de liberdade (ou DOF, da sigla em inglês, *Degree of Freedom*), abrindo e fechando uma garra pela ação de músculos antagônicos (HAKONEN; PIITULAINEN; VISALA, 2015).

---

<sup>1</sup> *Biofeedback* é uma ferramenta terapêutica que fornece informações sobre processos fisiológicos através de aparelhos sensórios, com a finalidade de permitir aos indivíduos, desenvolver a capacidade de autorregulação.



**Figura 1 – Histórico das principais interfaces desenvolvidas com sEMG.**

**Fonte: Hakonen, Piitulainen e Visala (2015), adaptado.**

Na década de 1980, começaram a surgir os primeiros trabalhos com o uso de sEMG para reconhecimento de padrões na fala. Dentre eles, Morse *et al.* (1989) apresentaram a possibilidade de reconhecer 10 palavras utilizando sEMG com taxas de acerto de 60%. Em 1999, Rosen, Fuchs e Arcan (1999) utilizaram sinais eletromiográficos, com estratégias de modelos musculares e Redes Neurais Artificiais, integrados em um exoesqueleto na junta do cotovelo. No início do século XXI, em 2001, foi realizado o estudo do uso de sEMG com uma cadeira de rodas com pessoas que possuíam alto nível de dano na medula espinhal (HAKONEN; PIITULAINEN; VISALA, 2015; HAN *et al.*, 2001).

Em 2004, surgiram os primeiros estudos em acoplar sensores de eletromiografia em braceletes (*armband*) com sistemas de reprodução de arquivos de áudio no formato mp3 (COSTANZA *et al.*, 2004, 2007). A primeira prótese comercial contendo múltiplos graus de liberdade foi realizada pela empresa Touch Bionics em 2007. A prótese, chamada i-limb, foi desenvolvida em forma de mão para uso de pessoas com o membro amputado (TOUCH BIONICS, 2016). Por fim, em 2013 foi apresentada comercialmente a interface em forma de *armband* Myo™, a qual funde dados de oito canais de EMG com sensores inerciais para reconhecimento de gestos e movimentos (THALMIC LABS, 2016). Assim sendo, uma das grandes características destes últimos sistemas mencionados é a utilização da abordagem de aquisição de múltiplos canais.

### 1.1 SISTEMAS MULTICANAIS E ARMBANDS

É perceptível que os sistemas para a aquisição e processamento de eletromiografia vêm sofrendo constantes evoluções e modificações, entre elas o uso


de análises de múltiplos canais (ou multicanais) de EMG. Como exemplos, citam-se os sistemas de reabilitação muscular de pacientes adoecidos ou acidentados (TSAI *et al.*, 2014); reconhecimento e identificação de movimentos, permitindo a interação homem–máquina para aplicações como controle de próteses, manipuladores e outros mecanismos robóticos (BLANCA *et al.*, 2016); e a interação com dispositivos físicos, como teclados, canetas e *joysticks* (HAKONEN; PIITULAINEN; VISALA, 2015).

Porém, através da revisão bibliográfica é possível perceber que as análises de EMG progridem para processamentos mais apurados com captura de múltiplos canais, onde destacam-se as *armbands*. Estas, de uma forma genérica, têm sido desenvolvidas para substituir os dispositivos de entradas habituais (ex: teclados, *joysticks*, etc.), com a finalidade de serem usadas em situações em que as mãos estejam ocupadas ou onde se deseja fazer interações particulares sem haver desconexões em um sistema (COSTANZA *et al.*, 2007).

Para justificar o conceito de *armband*, pode-se analisar o funcionamento de diferentes interfaces que não utilizam as mãos. As interfaces de visão apresentam resultados promissores em pesquisas, porém são dependentes de fatores como iluminação e obstrução (SAPONAS *et al.*, 2010). Sistemas de reconhecimento por voz podem permitir a atuação de dispositivos sem a necessidade de mãos, mas podem soar inadequados e pouco funcionais em ambientes sociais onde o ruído pode interferir criticamente (SAPONAS *et al.*, 2010). Comparativamente, sistemas em formato de *armbands* com sEMG apresentam vantagens, pois o usuário pode monitorar os gestos feitos por seu membro superior como entrada de sistemas, com um nível menor de interferências do meio sobre a aplicação. Além disso, as *armbands* podem captar sinais proveniente da ação dos dedos, processá-los e decodificá-los através do próprio braço. Ou seja, um dispositivo ligado ao antebraço pode reconhecer ações pertinentes a um conjunto muscular, aos dedos e ao membro superior por completo. Com essa exemplificação, pode-se visualizar na Figura 2 alguns dos casos mais relevantes do uso de *armbands* com sEMG encontrados na literatura.

Os trabalhos feitos por Costanza *et al.* (2004, 2007), mencionados anteriormente, aliaram a aquisição de EMG com um equipamento vestível, sendo este um dos pontos em comum com todos os outros trabalhos que usam o termo *armband* para designar tal dispositivo. A Figura 2a apresenta o dispositivo final, o qual continha três eletrodos (dois para a captura do sinal de um canal de sEMG e um para referência) e o circuito eletrônico em um bracelete, com a conexão dos eletrodos sobre





**Figura 2 – a) Primeiro sistema *armband* com sEMG publicado, b) *armband* usada para reconhecimento de gestos da mão, em destaque os eletrodos costurados no bracelete, c) *armband* com uso de fusão de sensores inerciais, d) protótipo de *armband* para identificação de gestos de motoristas e e) *armband* comercial Myo™.**

**Fonte: Costanza *et al* (2007); Saponas *et al* (2010); Cannan e Hu (2012); Allum, Hussain e Maloney (2014); Thalmic Labs (2016), adaptado**

os músculos do bíceps. Costanza *et al.* (2007) defendem que uma das necessidades desses tipos de dispositivos é o oferecimento de interações de forma facilitada, com movimentos naturais e muitas vezes imperceptíveis (tanto em sua vestimenta quanto na natureza dos gestos). Neste trabalho, foram usadas apenas ações musculares isométricas, em que a atividade muscular não produz necessariamente um movimento. A respeito de sua parte técnica, o circuito de captura desenvolvido foi baseado em um sistema de aquisição de eletrocardiografia (ECG), junto com um microcontrolador e um transmissor Bluetooth. Os dados processados comandavam uma interface móvel que selecionava menus em um rádio com taxa de acerto acima de 90%.

Em 2010, uma *armband* foi desenvolvida por Saponas *et al.* (Figura 2b) contendo seis canais diferenciais de aquisição de sEMG que reconhecia apenas dois tipos de gestos feitos com a mão. Os gestos reconhecidos foram a prensão do polegar com os demais dedos e a flexão de cada dedo com a palma da mão. Não foi realizado nenhum processamento ou condicionamento na placa, sendo todo ele desenvolvido em *software*. Através de Máquinas de Suporte Vetorial<sup>2</sup>, conseguiu-se taxas de acerto de 86% no reconhecimento dos gestos escolhidos.

Cannan e Hu (2012) construíram uma *armband* que unia os conceitos de fusão de dados de sensores inerciais (acelerômetros, giroscópios e magnetômetros) com sinais de sEMG (Figura 2c). Os dados adquiridos foram usados para a

<sup>2</sup> Máquinas de Suporte Vetorial são sistemas usados para classificação de dados por meio de aprendizagem supervisionada baseada no cálculo de hiperplanos.

identificação de movimentos e de comandos para serem aplicados em um manipulador robótico. Esse sistema foi comparado com formas clássicas de controle robótico, como teclado e *joystick*. Mesmo ainda não conseguindo superar a precisão destas interfaces, os autores concluíram que a *armband* possuía resultados promissores.

A Figura 2d apresenta uma plataforma que utilizava sensores inerciais com sinais de sEMG para reconhecer gestos feitos por condutores de veículos de trânsito para a prevenção de acidentes (ALLUM; HUSSAIN; MALONEY, 2014). Ao total, seis gestos foram reconhecidos pelo sistema, chamado de  $\mu$ -E. Ao reconhecer um gesto feito pelo motorista, este recebe um sinal sonoro em forma de comando de voz. O desafio do  $\mu$ -E foi construir uma *armband* que não necessitasse de treinamento para reconhecer os gestos, porém os autores concluíram que poderiam obter melhores resultados ao implementar essa etapa (ALLUM; HUSSAIN; MALONEY, 2014).

Um dos destaques no campo das *armbands* é o produto comercial Myo™, desenvolvido pela empresa ThalmicLabs (Figura 2e). Essa *armband* possui oito canais de aquisição de sinais sEMG que realizam a detecção de movimentos com a integração de sensores inerciais. Segundo o fabricante, suas aplicações envolvem o controle para a movimentação de veículos aéreos não tripulados e robôs, a conexão com dispositivos como computadores, televisão, plataformas de apresentação, sistemas *smart*, entre outros (THALMIC LABS, 2016). Essa plataforma utiliza os sinais eletromiográficos provenientes dos músculos da região do antebraço, como o palmar longo, flexor digital superficial e flexor do carpo ulnar.

O que chama atenção na plataforma Myo™ é o posicionamento dos eletrodos e o processamento desses sinais, os quais dependem apenas de apenas uma orientação pré-determinada pelo fabricante que deve ser obedecida pelo usuário para sua calibração adequada. Esta posição não fixada nem segue rigorosos padrões como em demais pesquisas. Na maioria dos sistemas multicanais os eletrodos são adequadamente posicionados para que os sinais de sEMG dos determinados músculos em questão sejam extraídos (BORBÉLY; SZOLGAY, 2013; LI, 2011; TSAI *et al.*, 2014). Porém, no Myo™, o próprio sistema possui um protocolo de calibração simplificado.

## 1.2 OBJETIVOS

### 1.2.1 Objetivo Geral

Desenvolver um dispositivo em formato de bracelete (*armband*) para a captação de sinais eletromiográficos de superfície do braço a fim de reconhecer seus movimentos. Este dispositivo analisa um conjunto de sinais provenientes de um antebraço captados por oito canais distribuídos equidistantemente no bracelete.

### 1.2.2 Objetivos Específicos

- Construir um sistema para alocação dos arranjos de eletrodos em forma de *armband* contendo oito canais ao redor do braço;
- Projetar circuitos de aquisição de sinais de sEMG;
- Aplicar e desenvolver um sistema com um sensor inercial no membro superior para indicar a movimentação do indivíduo;
- Desenvolver um módulo via *software* para a aquisição dos sinais de sEMG e do sensor inercial de forma sincronizada para a montagem de um banco de dados;
- Elaborar, em *software*, um sistema de tratamento e processamento dos sinais presentes no banco de dados, contendo a extração das características de sEMG;
- Desenvolver uma Rede Neural Artificial para a classificação dos dados de sEMG referentes aos movimentos de flexão e extensão do braço;
- Avaliar os resultados obtidos.

## 1.3 JUSTIFICATIVA

Conforme apresentado anteriormente, sistemas multicanais em forma de *armband* estão em constante desenvolvimento. Entretanto, ainda não há pesquisas nacionais relevantes publicadas sobre o desenvolvimento de um sistema nesse formato (*armband*) para a captura de sinais de sEMG para interfaces.

As *armbands* são opções de sistemas de captura de sEMG e seu estudo justifica-se pelos diversos propósitos em que pode ser aplicada. Suas aplicações envolvem desde as mais clássicas, como controle atuação de sistemas eletroeletrônicos por meio de gestos, até sistemas de reabilitação e controle de próteses ou órteses utilizando eletromiografia. Logo, o desenvolvimento e validação do hardware de captura é o primeiro passo para diferentes aplicações futuras de controle e/ou monitoramento utilizando sEMG, realizadas em software.

#### 1.4 ORGANIZAÇÃO DA DISSERTAÇÃO

Este trabalho está organizado na seguinte divisão:

- O capítulo 2 apresenta uma revisão bibliográfica dos principais conceitos relacionados a fisiologia muscular, anatomia do braço, instrumentação de sinais eletromiográfico, seu processamento, além dos conceitos de fusão de sensores e de redes neurais;
- No capítulo 3 é apresentada a metodologia do desenvolvimento da *armband* e do sistema de reconhecimento;
- O capítulo 4 aborda as etapas de desenvolvimento da *armband*, desde a concepção física, circuitos de condicionamento, *softwares* de aquisição e de condicionamento e as características da implementação da Rede Neural Artificial;
- O capítulo 5 expõe os resultados obtidos durante cada uma das etapas do desenvolvimento e levanta a sua discussão;
- O capítulo 6 apresenta as considerações finais e os trabalhos futuros.

## 2 REVISÃO BIBLIOGRÁFICA

Nessa seção, são abordadas as origens do sinal eletromiográfico, as técnicas de instrumentação e condicionamento do sinal, as características dos sistemas de processamento de sinal, com uma explanação sobre os sistemas de Redes Neurais Artificiais e Fusão de Sensores, com enfoque nos sensores inerciais.

### 2.1 ORIGEM DO SINAL ELETROMIOGRÁFICO

O sinal obtido da EMG é classificado como um sinal de natureza bioelétrica e é considerado um biopotencial (COHEN, 2000). Origina-se no cérebro humano (Figura 3) com a formação do pensamento do movimento nos lobos frontais, passando pelo córtex pré-frontal e córtex motor primário para localização da posição geral do corpo onde o movimento será realizado (CRISWELL, 2011). Essa informação é enviada para a medula espinhal, onde existem neurônios motores (ou motoneurônios) responsáveis pela condução do impulso até as fibras musculares esqueléticas, ou seja, voluntárias, onde estão localizadas as unidades motoras.

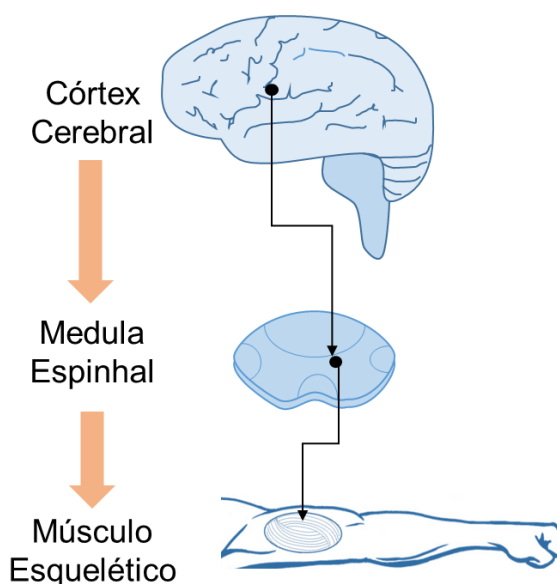


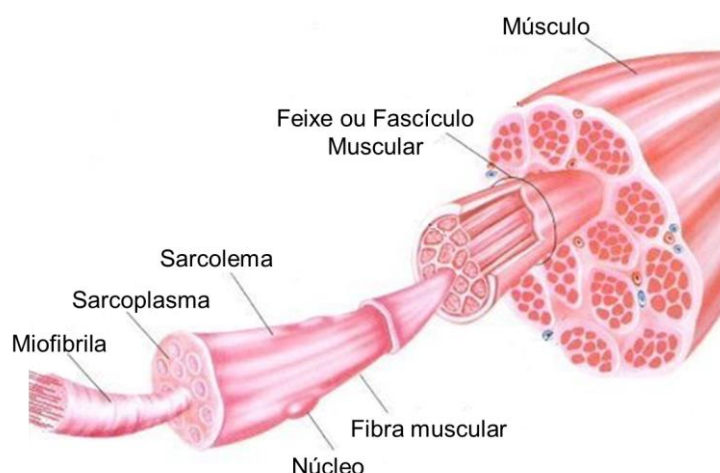
Figura 3 – Representação dos elementos básicos do controle motor.  
Fonte: Moritani, Stegeman e Merletti (2004), adaptado

### 2.1.1 Unidade Motora

É chamado de unidade motora (UM) o conjunto de fibras musculares inervadas em um motoneurônio, também chamado de motoneurônio-alfa (POZZO; FARINA; MERLETTI, 2004). De acordo com Kamen e Gabriel (2015), o termo UM foi descrito por Sherrington em 1906; e na EMG, os biopotenciais mensurados são pertencentes a sua ação. Para a compreensão total do seu funcionamento, é necessário aprofundar-se nas ações do neurônio, nas características das fibras musculares e nos Potenciais de Ação (PA).

Um neurônio é a célula básica do sistema nervoso, composto por corpo celular (também chamado de soma), dendritos e axônio (CARR; BROWN, 2001). O soma é parte que possui citoplasma, núcleo e organelas celulares; os dendritos são pequenas ramificações que oferecem ampla área de contato para a recepção de informações e de estímulos para o corpo celular (GUYTON; HALL, 2011). A informação recebida nos dendritos e concentrada no corpo celular é transmitida por meio do axônio para outros neurônios ou fibras musculares, a qual é a sua função. O axônio é composto por capas isolantes de mielina e possui terminações não isoladas, chamadas de Nódulos de Ranvier, que aceleram a transmissão do impulso nervoso (CARR; BROWN, 2001).

A estrutura de um músculo esquelético é apresentada na Figura 4. Os músculos esqueléticos estão conectados aos ossos e permitem a realização de movimentos (TRIPLETT, 2015). Um músculo é composto por um agrupamento de feixes ou fascículos musculares que, em uma visão macroscópica, permitem analisar a direção das fibras, as origens e inserções do músculo e suas linhas de ação (CRISWELL, 2011; TRIPLETT, 2015). Os fascículos são compostos por fibras musculares, revestidas por uma membrana chamada sarcolema (CRISWELL, 2011; GUYTON; HALL, 2011). Os núcleos das células musculares localizam-se ao longo da fibra muscular. O sarcoplasma, ou retículo sarcoplasmático, possui alta concentração de Cálcio (Ca), que é liberado durante a contração muscular. Cada fibra muscular é composta por miofibrilas, e estas, por sua vez, são compostas por filamentos de miosina e actina: longas moléculas de proteínas que realizam as contrações musculares (GUYTON; HALL, 2011).




**Figura 4 – Estrutura de um músculo esquelético.**  
**Fonte: Triplett (2015), adaptado.**

O próximo elemento a ser analisado é o PA. Esses sinais podem ser descritos como variações rápidas dos potenciais externos e internos das membranas de células excitáveis, como fibras musculares e neurônios. O fenômeno do tudo-ou-nada de um PA é perceptível pela alteração abrupta de um potencial de repouso de magnitude negativa para um potencial positivo com um retorno rápido para o negativo (GUYTON; HALL, 2011; KANDEL; BARRES; HUDSPETH, 2013). De acordo com Guyton e Hall (2011), os PAs são amplamente usados pelo sistema nervoso para a comunicação entre os tecidos, glândulas e o próprio sistema nervoso.

Como apresentado pela Figura 5, o PA possui três fases distintas. A primeira delas, o repouso, é caracterizado pelo potencial negativo que existe entre o interior e o exterior celular (entre os dois lados da membrana plasmática). Durante o repouso, o gradiente dessa tensão fica em torno de -90 a -70 mV nas fibras musculares (KAMEN; GABRIEL, 2015; POZZO; FARINA; MERLETTI, 2004). No interior da célula, existe uma grande concentração de íons de Potássio ( $K^+$ ), e externamente, íons de Sódio ( $Na^+$ ). Quando há a realização de algum estímulo (seja ele de origem elétrica, mecânica, física ou química), há um aumento da permeabilidade da membrana plasmática aos íons de  $Na^+$ , o que inicia o potencial de ação (CARVALHO, 2008; GUYTON; HALL, 2011). Essa fase é conhecida como despolarização, pois os íons se movem para o interior da célula, deixando-a com tensão de membrana positiva. O pico positivo pode atingir valores que, segundo autores, variam de +10 mV ou mais (KAMEN; GABRIEL, 2015). Ao atingir o máximo de despolarização na célula, a membrana torna-se menos impermeável ao  $Na^+$  e também ocorre um aumento da

permeabilidade ao  $K^+$ , pois os canais de sódio na membrana começam a se fechar enquanto que os canais de potássio se abrem mais que o normal (CARR; BROWN, 2001; GUYTON; HALL, 2011). Esse estágio, o último, é chamado de repolarização, tornando o interior da célula novamente mais negativo que o exterior.



**Figura 5 – Potencial de Ação típico.**  
**Fonte: Guyton e Hall (2011), adaptado.**

A partir dos conceitos apresentados, pode-se compreender o comportamento do músculo durante uma contração voluntária. De acordo com Guyton e Hall (2011), quando há intenção do movimento, os PAs de um motoneurônio cursam até as terminações do axônio que estão atreladas as fibras musculares. Em cada terminação, uma pequena quantidade de acetilcolina (uma substância neurotransmissora) é secretada pelo neurônio. Essa substância abre múltiplos canais de cátions em uma área da membrana da fibra muscular (GUYTON; HALL, 2011). Os canais abertos pela acetilcolina causam a ação do PA nas fibras musculares pela despolarização local, se propagando por toda a fibra como ocorre nas células nervosas.


Grande parte da eletricidade do PA flui pelo centro da fibra muscular, o que faz com que o sarcoplasma libere uma grande quantidade de íons de cálcio (os quais estão nele armazenados). Os íons de cálcio fazem com que os filamentos de miosina e actina deslizem ao lado um do outro, realizando o processo de contração. Em uma fração de segundo, os íons de cálcio são bombeados para retornarem ao sarcoplasma (por meio de uma bomba do íon de cálcio  $Ca^{++}$ ), onde ficam armazenados até o início de um novo PA. A remoção dos íons de cálcio das miofibrilas cessa a contração



muscular (GUYTON; HALL, 2011), fazendo com que a UM aguarde até a próxima realização do movimento.

O número de fibras musculares por UM (chamada de taxa de inervação) pode variar de poucas unidade até milhares (KAMEN; GABRIEL, 2015). Como exemplo, a taxa de inervação pode ser alta, como no gastrocnêmio (no estômago) com 2 mil fibras musculares para cada UM, ou baixa, como os músculos dos olhos, com 10 fibras por UM (KAMEN; GABRIEL, 2015; POZZO; FARINA; MERLETTI, 2004).

O disparo de um motoneurônio resulta em uma descarga de muitas fibras musculares de forma quase simultânea (KAMEN; GABRIEL, 2015). Ao somar todas as atividades das fibras gera-se um Potencial de Ação de Unidade Motora (PAUM ou *MUAP*, do inglês, *Motor Unity Action Potential*). A Figura 6 apresenta como ocorre a formação do PAUM ao longo das fibras musculares, que consiste em um somatório espaço temporal dos PAs gerados por um motoneurônio-alfa (motoneurônio- $\alpha$ ). Portanto, o sinal de EMG é a resultante da atividade elétrica das UMs recrutadas em uma contração muscular (BASMAJIAN; DE LUCA, 1985).



**Figura 6 – Representação do processo de propagação de PA e registro de PAUMs por meio da superfície da pele.**

**Fonte: Stevan Jr et al. (2015).**

Antes, porém, de analisar os sistemas de aquisição do sinal eletromiográfico, faz-se necessário apresentar as características anatômicas dos músculos a serem investigados.

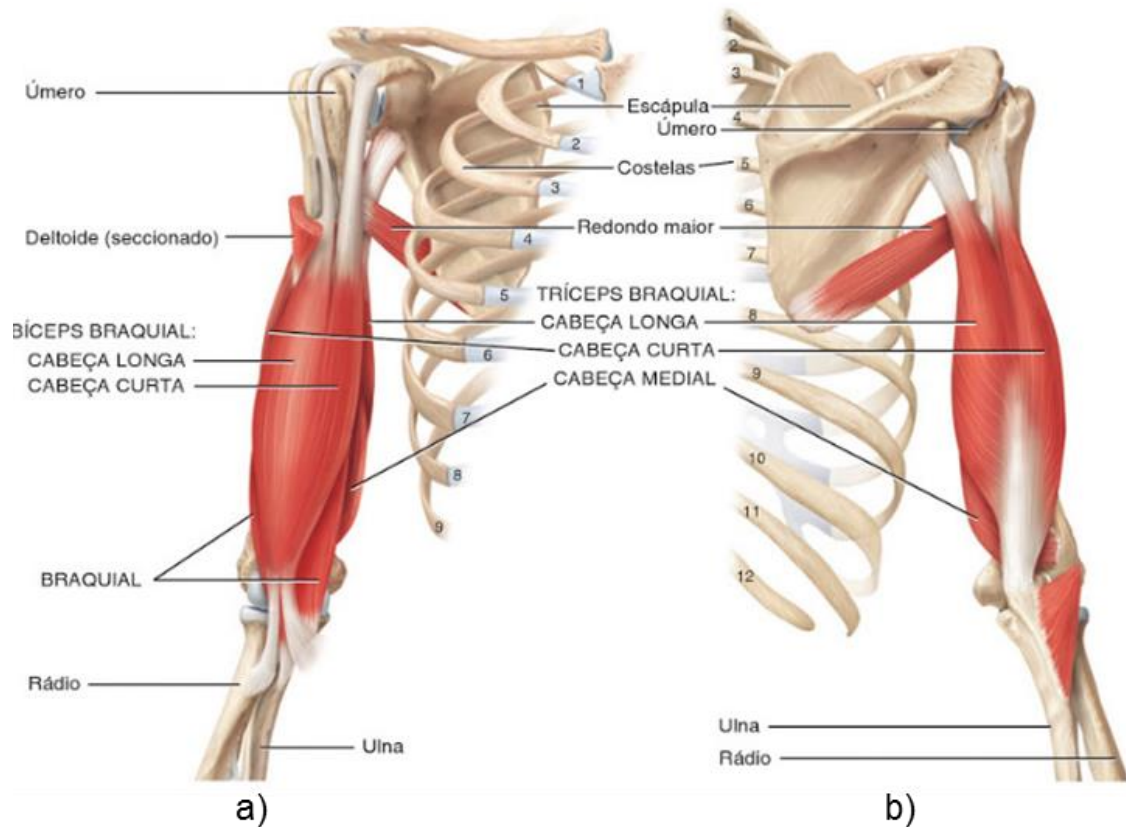
## 2.2 PRINCIPAIS CONCEITOS DE ANATOMIA MUSCULAR DOS MEMBROS SUPERIORES

Anatomicamente, o membro superior pode ser dividido em três partes principais: braço, antebraço e mão. Essa divisão está relacionada com os ossos a elas atreladas: úmero (braço); rádio e ulna (antebraço); e carpo, metacarpo e falanges (mão) (TORTORA; DERRICKSON, 2012).

Em maior parte, o membro superior é composto por músculos estriados esqueléticos. Os músculos esqueléticos possuem a presença de uma porção média chamada de ventre muscular, em que predominam-se as fibras musculares. Nas suas extremidades, seu formato torna-se cilíndrico de tal forma que prendem o músculo ao esqueleto com uma camada de tecido conjuntivo, os quais são chamados de tendões (DANGELO; FATTINI, 2011).

A Figura 7 ilustra a posição e os principais músculos da região do braço. Os músculos do braço estão divididos entre flexores e extensores. Os flexores (responsáveis pelo movimento de flexão) são os músculos bíceps braquial (ou bíceps do braço), braquial e braquiorradial, presentes na vista anterior (Figura 7a). O bíceps braquial flexiona o braço enquanto flete e supina o antebraço; o braquiorradial e o braquial apenas fletem o antebraço. Por outro lado, como extensor, apenas há a ação do tríceps, que estende tanto o braço quanto o antebraço, apresentado na visão posterior (Figura 7b) (CRISWELL, 2011; TORTORA; DERRICKSON, 2012).

No antebraço estão dispostos uma maior quantidade de músculos, conforme ilustrado na Figura 8. Dentre os principais, no grupo dos flexores (Figura 8a) estão o flexor radial do carpo (que flexiona e aduz a mão no punho), o flexor ulnar do carpo (que fracamente flexiona a mão na articulação do punho), o palmar longo (flexiona a mão no punho e as falanges do segundo ao quinto dedos) e o flexor superficial dos dedos (que flexiona a articulação do punho e as falanges de cada dedo). No grupo dos extensores (Figura 8b), encontram-se o extensor radial longo do carpo, o extensor ulnar do carpo (que estendem e abduzem a mão na articulação do punho) e o extensor dos dedos (que estendem a mão na articulação do punho e as falanges do segundo



**Figura 7 – Músculos do braço nas vistas a) anterior e b) posterior.**  
**Fonte: Tortora e Derrickson (2012), adaptado.**


ao quinto dedo) (CRISWELL, 2011; TORTORA; DERRICKSON, 2012).

### 2.3 INSTRUMENTAÇÃO DO SINAL ELETROMIOGRÁFICO

O sinal de EMG possui uma aparência ruidosa, forte característica estocástica e de difícil interpretação visual (NAJARIAN; SPLINTER, 2012). Diversos recursos podem contribuir para reduzir interferências e melhorar a qualidade do sinal. As principais etapas comumente existentes na aquisição e condicionamento estão apresentadas na Figura 9, as quais são abordadas a seguir.

#### 2.3.1 Eletrodos

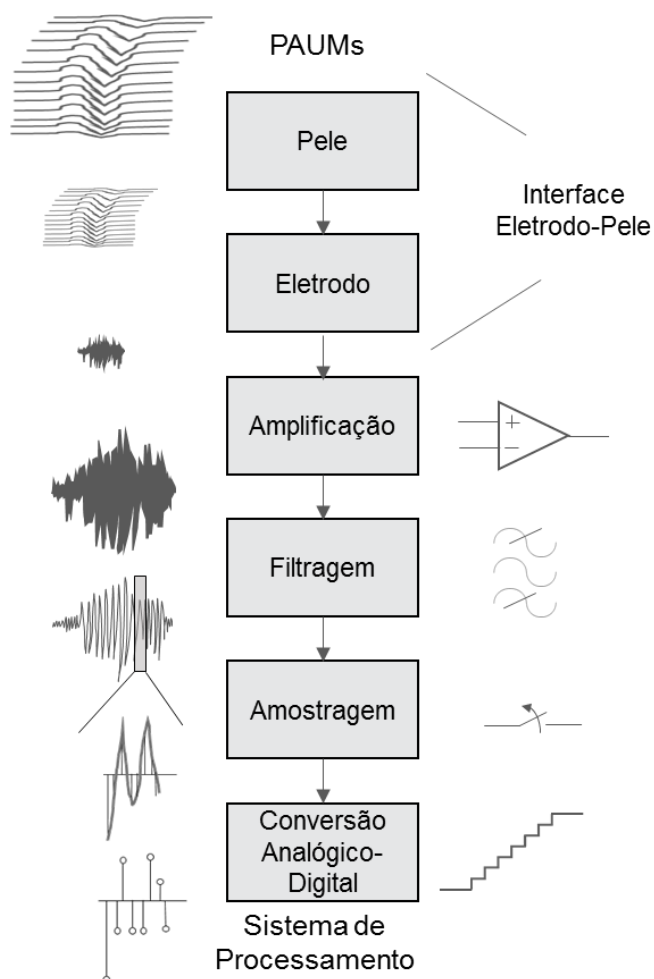
A primeira questão sobre a aquisição do sinal de EMG é como este é captado (CRISWELL, 2011; DE LUCA, 2006; JAMAL, 2012). Existem duas vertentes principais no estudo e uso da EMG: a eletromiografia invasiva e a não invasiva, sEMG (CRISWELL, 2011; HAKONEN; PIITULAINEN; VISALA, 2015).



**Figura 8 – Músculos do antebraço nas vistas a) anterior superficial e b) posterior superficial.**  
**Fonte: Tortora e Derrickson (2012), adaptado.**

A eletromiografia invasiva utiliza eletrodos que fazem a coleta do sinal das fibras musculares, perfurando a pele (KAMEN; GABRIEL, 2015). Por outro lado, a sEMG realiza a medição dos PAUMs por meio de eletrodos localizados na superfície da pele (CRISWELL, 2011). Ambos os tipos de eletrodos são feitos de metais condutores e são responsáveis por converter os sinais dos potenciais em um sinal elétrico (KAMEN; GABRIEL, 2015; MERLETTI; HERMENS, 2004).

Os eletrodos invasivos, como os eletrodos de agulha ou de fio, são usados em ambientes clínicos e de pesquisa com foco em contrações musculares estáticas e nas atividades e comportamento de UMs individuais (KAMEN; GABRIEL, 2015; TRONTELJ; JABRE; MIHELIN, 2004). Com esse sinal, é possível observar se houve deservação do músculo (perda da conexão com o motoneurônio), reinervação (regeneração do nervo) e doenças musculares (como miopatias) e neuromusculares (TRONTELJ; JABRE; MIHELIN, 2004). Isso ocorre porque esse tipo de eletrodo capta



**Figura 9 – Etapas de aquisição e pré-processamento do sinal de sEMG.**  
**Fonte: Autoria própria.**

de uma a poucas unidades motoras no músculo, fornecendo grande seletividade das fibras escolhidas (KAMEN; GABRIEL, 2015). Porém, os modelos invasivos podem causar incômodo e permitem pouca movimentação do paciente.


Por outro lado, os eletrodos não invasivos não apresentam grande desconforto ao paciente, pois são alocados na superfície da pele. São fabricados com prata sintetizada ou cloreto de prata, ouro, platina, irídio e aço inoxidável (KAMEN; GABRIEL, 2015; POZZO; FARINA; MERLETTI, 2004). Como desvantagem, os eletrodos não invasivos limitam-se apenas aos músculos superficiais, não podendo isolar a ação apenas um músculo, possuindo baixa seletividade e maior susceptibilidade a ruídos e *crosstalk* muscular (FRIDLUND; CACIOPPO, 1986). Com relação ao tamanho e ao formato dos eletrodos, não há recomendações específicas, pois os mesmos não oferecem grande influência na taxa de acerto de sistemas de classificação (HAKONEN; PIITULAINEN; VISALA, 2015). Os modelos não invasivos

podem ser caracterizados com gel ou secos e passivos ou ativos (HAKONEN; PIITULAINEN; VISALA, 2015; KAMEN; GABRIEL, 2015).

Os eletrodos que possuem gel são amplamente utilizados em sistemas de sEMG. O gel condutor atua como uma ponte eletrolítica, mantendo um caminho condutivo entre a superfície metálica e a pele, além de ajudar na atenuação de artefatos de movimento. Por sua vez, os eletrodos secos não possuem gel condutor e podem apresentar alta impedância entre eletrodo-pele e alta susceptibilidade aos artefatos de movimento. Entretanto, estudos e desenvolvimentos recentes apontam novos modelos com alta fidelidade comparados aos eletrodos que possuem gel condutor (HAKONEN; PIITULAINEN; VISALA, 2015; LAFERRIERE; CHAN; LEMAIRE, 2010; MERLETTI; HERMENS, 2004).

Os eletrodos considerados passivos não possuem sistemas eletrônicos adicionais acoplados em sua unidade. Por sua vez, os eletrodos ativos possuem um pré-amplificador alocados junto ao eletrodo. São usados ganhos de amplificação, comumente entre a faixa de 1 a 10, antes que o sinal seja enviado para a unidade de processamento (KAMEN; GABRIEL, 2015).

Existem dois principais modos de configuração dos eletrodos: monopolar e bipolar, apresentados na Figura 10. A configuração monopolar é composta da alocação de um eletrodo na fibra muscular e outro em uma área eletricamente neutra (estrutura óssea ou com sinais elétricos não relacionados com a região de interesse) (DE LUCA, 2006). Em contrapartida, na configuração bipolar são inseridos dois eletrodos nas extremidades do feixe muscular e um eletrodo em uma região eletricamente neutra. Os sinais entre as extremidades do músculo são subtraídos (por meio de um amplificador diferencial), o que resulta em uma melhora na qualidade do sinal pela atenuação dos ruídos comuns no músculo (como sinal de 60 Hz) (DE LUCA, 2006). Essa é uma vantagem em relação a configuração monopolar, pois essa capta todos os sinais elétricos e os ruídos da região a ser analisada. Em trabalhos que visam classificação e reconhecimento de padrões, os eletrodos são configurados em modo bipolar, com a alocação do eletrodo de referência em músculos específicos ou entre os eletrodos diferenciais de forma equidistante (HAKONEN; PIITULAINEN; VISALA, 2015). Com relação a distância entre eletrodos, recomenda-se utilizar entre 1 a 2 cm (HAKONEN; PIITULAINEN; VISALA, 2015; HERMENS *et al.*, 2000).




**Figura 10 – Modos de configuração dos eletrodos: a) monopolar e b) bipolar.**  
**Fonte: Autoria própria.**

Além do modo de configuração, outro fator que exerce grande influência ao sinal é o posicionamento dos eletrodos (DE LUCA, 1997). A localização dos eletrodos pode melhorar a relação sinal-ruído e afeta o valor da amplitude e das frequências coletadas a partir da pele. Isso ocorre porque a impedância das camadas da pele atenuam os sinais até a superfície de captação (HAKONEN; PIITULAINEN; VISALA, 2015; MERLETTI *et al.*, 2009). Outro fenômeno decorrente do posicionamento é o *crosstalk* que pode ocorrer com a ação de grupos musculares vizinhos à área em que o sinal é adquirido (DE LUCA, 1997). A grande maioria dos trabalhos orienta e posiciona os eletrodos paralelamente as fibras musculares (o que ocasiona aumento da seletividade e sensibilidade do músculo em questão); enquanto que estudos que visam informações de grupos musculares de forma global utilizam-se de posicionamento e orientação transversais às fibras (DE LUCA, 1997; HAKONEN; PIITULAINEN; VISALA, 2015).

O número de eletrodos e de canais também é um dos temas de estudos de pesquisas. Em estudos em laboratórios, percebe-se que há uma questão em quantidade de dados para se processar e a taxa de acerto do classificador. Alguns estudos para casos específicos do antebraço mostram que 4 a 5 canais podem providenciar taxas de acerto semelhantes do que o uso de 7 a 8 canais (FARRELL; WEIR, 2008). Para o controle através de EMG, Hargrove, Englehart e Hudgins (2007) apresentaram que 4 canais são suficientes para reconhecer 10 classes de movimento; o aumento do número de eletrodos não melhorou a taxa de acerto para aplicação requerida. Em outro exemplo, Young, Hargrove e Kuiken (2012) recomendaram o uso de 4 a 6 canais em modo transradial para diminuição de erros em deslocamento de eletrodos. Ou seja, o número de canais varia de acordo com cada aplicação, porém, a adição de canais requer um maior custo do sistema de aquisição (MERLETTI; HERMENS, 2004).

### 2.3.2 Característica dos sinais de sEMG

O sinal captado através dos eletrodos de superfície possui amplitudes variando de 50  $\mu\text{V}$  até 5 mV com frequências entre 20 e 500 Hz (COHEN, 2000; DE LUCA, 2006; MERLETTI; HERMENS, 2004), como está ilustrado na Figura 11. Dentre essa faixa de frequência, a energia dominante do sinal se concentra entre 50 e 150 Hz (BASMAJIAN; DE LUCA, 1985). De uma maneira geral, (FRIDLUND; CACIOPPO, 1986) afirmam que entre 10 e 200 Hz concentra-se a energia primária de sEMG, entre 10 e 30 Hz correspondem as taxas de disparo das UMs e a ação das PAUMs ocorre acima de 30 Hz.



**Figura 11 – Exemplo do sinal de sEMG, nos domínios a) do tempo e b) da frequência.  
Fonte: Autoria própria.**

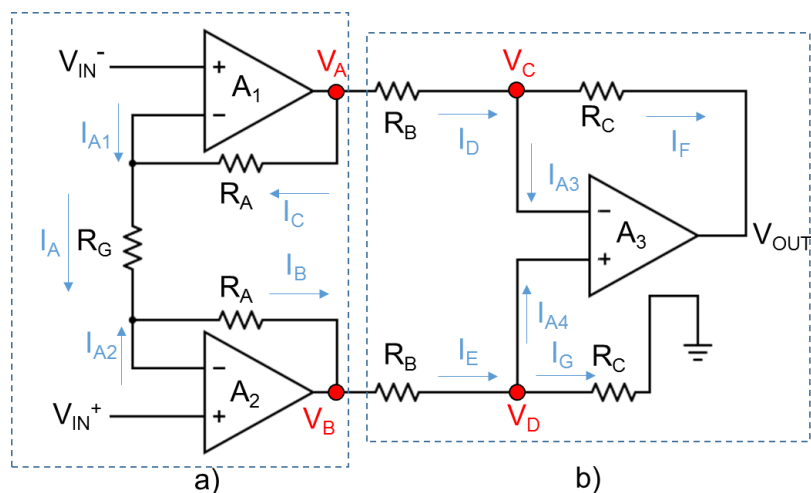


### 2.3.3 Amplificação

Como os sinais de sEMG possuem baixas amplitudes, é necessário que haja a ação de um amplificador para aumentar os valores de suas magnitudes a fim de fornecer um sinal de qualidade e com nível de tensão adequado para as etapas de processamento (NAGEL, 2000).

Amplificadores de Instrumentação são usados em sEMG como primeiro estágio de entrada do sinal. O uso deste modelo, exemplificados na configuração bipolar, possui uma série de características vantajosas para essa aplicação (MERLETTI *et al.*, 2009).

O circuito de um amplificador de instrumentação (Figura 12) é composto por três amplificadores operacionais. Os amplificadores  $A_1$  e  $A_2$  são amplificadores não inversores que atuam como estágios de entrada do circuito (Figura 12a), enquanto que o amplificador  $A_3$  é um amplificador diferencial (Figura 12b) (KITCHIN; COUNTS, 2006; TEXAS INSTRUMENTS, 1995).



**Figura 12 – Esquemático de um amplificador de instrumentação, em destaque a) seus estágios de entrada e b) seu amplificador diferencial.**

Fonte: Autoria própria.

Seu comportamento pode ser analisado pela obtenção de sua função de transferência. Utilizando as nomenclaturas para as correntes e tensões presentes na Figura 12, pode-se iniciar este processo pelos amplificadores do estágio de entrada. Pela alta impedância existentes entre a entrada inversora e não-inversora, as correntes  $I_{A1}$  e  $I_{A2}$  podem ser consideradas como nulas. E pela condição de curto circuito virtual, as tensões  $V_{IN^-}$  e  $V_{IN^+}$ , presentes nas entradas não-inversoras, são as

mesmas nas entradas inversoras. Dessa forma, a equação (1) apresenta a malha contendo a diferença de tensão entre  $V_A$  e  $V_B$

$$V_B - V_A = I_C R_A + I_A R_G + I_B R_A \quad (1)$$

As correntes  $I_A$ ,  $I_B$  e  $I_C$  são a mesma corrente (chamada  $I$ , pois  $I_{A1}$  e  $I_{A2}$  são nulas), pode-se escrever (1) como a equação (2)

$$\begin{aligned} V_B - V_A &= I R_A + I R_G + I R_A \\ V_B - V_A &= I(2R_A + R_G) \end{aligned} \quad (2)$$

Pela ação do curto circuito virtual, equaciona-se as entradas como em (3)

$$\begin{aligned} V_{IN}^+ - V_{IN}^- &= I_A R_G \\ V_{IN}^+ - V_{IN}^- &= I R_G \end{aligned} \quad (3)$$

Isolando  $I$  da equação (2), obtém-se a equação (4)

$$I = \frac{V_B - V_A}{R_G} \quad (4)$$

E substituindo a equação (4) em (3), tem-se a equação (5)

$$\begin{aligned} \frac{V_B - V_A}{V_{IN}^+ - V_{IN}^-} &= \frac{I(2R_A + R_G)}{I R_G} \\ \frac{V_B - V_A}{V_{IN}^+ - V_{IN}^-} &= \frac{2R_A + R_G}{R_G} \therefore \frac{V_B - V_A}{V_{IN}^+ - V_{IN}^-} = \frac{2R_A}{R_G} + 1 \end{aligned} \quad (5)$$

Com a equação (5), obtém-se a função de transferência do estágio de entrada. O passo seguinte é a retirada da função de transferência do amplificador diferencial. Tomando como base a Figura 12b e sabendo que  $I_{A3}$  e  $I_{A4}$  são nulas, pode-se obter as equações dos nós  $V_C$  e  $V_D$  (por análise nodal) em (6) e (7)

$$\begin{aligned}
 I_D &= I_F \\
 \frac{V_A - V_C}{R_B} &= \frac{V_C - V_{OUT}}{R_C} \\
 \frac{V_A}{R_B} + \frac{V_{OUT}}{R_C} &= V_D \left( \frac{1}{R_B} + \frac{1}{R_C} \right)
 \end{aligned} \tag{6}$$

$$\begin{aligned}
 I_E &= I_G \\
 \frac{V_B - V_D}{R_B} &= \frac{V_D}{R_C} \\
 V_D &= \frac{V_B (R_C R_B)}{R_B (R_B + R_C)}
 \end{aligned} \tag{7}$$

Como  $V_C$  e  $V_D$  são iguais (curto circuito virtual), pode-se substituir a equação (7) em (6), obtendo-se a equação (8), que rearranjada, torna-se a função de transferência do amplificador diferencial:

$$\begin{aligned}
 \frac{V_A}{R_B} + \frac{V_{OUT}}{R_C} &= \frac{V_B (R_C R_B)}{R_B (R_B + R_C)} \left( \frac{1}{R_B} + \frac{1}{R_C} \right) \\
 \frac{V_A}{R_B} + \frac{V_{OUT}}{R_C} &= \frac{V_B (R_C R_B)}{R_B (R_B + R_C)} \left( \frac{R_B + R_C}{R_B R_C} \right) \\
 \frac{V_A}{R_B} + \frac{V_{OUT}}{R_C} &= \frac{V_B}{R_B} \\
 \frac{V_{OUT}}{R_C} &= \frac{V_B - V_A}{R_B} \\
 \frac{V_{OUT}}{V_B - V_A} &= \frac{R_C}{R_B}
 \end{aligned} \tag{8}$$

Unindo os dois estágios, ou seja, multiplicando as funções de transferências presentes nas equações (5) e (8), obtém-se (9) que é a função característica do amplificador de instrumentação

$$\frac{V_{OUT}}{V_{IN}^+ - V_{IN}^-} = \left( \frac{2R_A + R_G}{R_G} \right) \frac{R_C}{R_B} \therefore \frac{V_{OUT}}{V_{IN}^+ - V_{IN}^-} = \left( \frac{2R_A}{R_G} + 1 \right) \frac{R_C}{R_B} \tag{9}$$

Além do seu funcionamento dado pela função de transferência, outras características importantes do amplificador de instrumentação são:

- Alta impedância de entrada: é necessário que o amplificador apresente em seu estágio de entrada uma impedância que seja, no mínimo, 100 vezes maior que a impedância entre a junção eletrodo-pele (MERLETTI *et al.*, 2009). Tomando como base o pior caso, o valor dessa junção é 1 M $\Omega$  para eletrodos secos, logo, o amplificador necessita de uma impedância de 100 M $\Omega$ . Impedâncias maiores que essa são recomendadas, além de que os amplificadores comerciais apresentam valores entre  $10^7$  a  $10^{12}$   $\Omega$ , com uma capacitância entre 2 a 12 pF (MERLETTI *et al.*, 2009). Uma alta impedância de entrada diminui distorções no sinal e aumenta a sua fidelidade (NEUMAN, 2010).
- Alta Taxa de Rejeição de Modo Comum (do inglês, *Common Mode Rejection Ratio*, CMRR): um alto valor de CMRR remete a uma redução de sinais que possuem valores comuns em ambos os terminais do amplificador. Nessa categoria, se enquadra a interferência da rede elétrica (60 Hz). Os valores comuns de CMRR nos amplificadores de instrumentação estão entre a faixa de 90 a 140 dB de rejeição (CRISWELL, 2011; FRIDLUND; CACIOPPO, 1986; MERLETTI *et al.*, 2009).
- Resposta em frequência e produto ganho largura-faixa: como todo amplificador, o amplificador de instrumentação também é sujeito a variações pela frequência do sinal de entrada. Sendo um amplificador de biopotenciais, é necessário que o amplificador de instrumentação opere na frequência do espectro de sEMG, como apresentado na seção seguinte (NEUMAN, 2010). Além disso, o produto ganho largura-faixa (que é a multiplicação do ganho por uma banda em determinada frequência) também deve ser verificada, pois decresce conforme aumenta-se o valor da frequência aplicada na entrada (WEBSTER, 2010). Nos amplificadores de instrumentação, tende-se a obter um alto valor, sendo que para ganhos unitários, pode-se chegar a casa das décadas de MHz.
- E outras características: baixo ruído de amplificação e dos terminais de entrada e proteção contra sobrecargas e falhas elétricas (CRISWELL, 2011; FRIDLUND; CACIOPPO, 1986; MERLETTI *et al.*, 2009).

Neste primeiro estágio, os amplificadores (em algumas nomenclaturas, pré-amplificadores) podem apresentar capacitores para atenuar e eliminar componentes de corrente contínua (DC, do inglês, *Direct Current*). Os valores dos ganhos são selecionados por meio de resistores externos aos amplificadores. Além disso, outros estágios de amplificação além dos pré-amplificadores são usados quando necessitam-se adequar a faixa de tensão para a entrada de sistemas de processamento, como em conversores analógico-digital (AD) (JAMAL, 2012; POZZO; FARINA; MERLETTI, 2004).

#### 2.3.4 Filtragem


A fim de limitar a banda do sinal analisado, é necessário o uso de filtros para atenuar interferências e garantir melhora na qualidade do sinal, pois as componentes ruidosas podem fornecer interpretações errôneas (DE LUCA *et al.*, 2010). Para tal, um passa-banda é usado, composto por estágios passa-baixa (atenuando as altas frequências) e passa-alta (atenuando as baixas frequências) em cascata (KAMEN; GABRIEL, 2015; POZZO; FARINA; MERLETTI, 2004).

Os ruídos de baixa frequência se classificam como os *offsets* DC, flutuações de temperatura e artefatos de movimento (deslocamento de eletrodos, cabos, gel condutor). Por outro lado, os ruídos de alta frequência ocorrem pela interferência de sistemas de comunicação (como computadores, celulares e transmissões de rádio) e outros biopotenciais do corpo humano, além de auxiliarem contra o *aliasing* (serrilhamento) do sinal no processo de amostragem (CRISWELL, 2011; JAMAL, 2012; KAMEN; GABRIEL, 2015; POZZO; FARINA; MERLETTI, 2004).

O ruído que possui a maior parcela de interferência ao sinal de sEMG é o da frequência da rede elétrica de distribuição (60 Hz no Brasil e 50 Hz em outros países) e seus harmônicos (PEDROSO, 2013). Para atenuar essa frequência, filtros rejeita-faixa (ou *notch*) são usados com frequência entre 59-61 Hz (CRISWELL, 2011). Entretanto, existem diversas opiniões quanto ao seu uso. Os filtros realizados de forma analógica causam distorção de fase, e no caso do rejeita-faixa, há inversão da fase nas bandas próximas a frequência de rejeição (OPPENHEIM; WILLISKY, 2010), as quais compreendem os domínios do sinal de sEMG (DE LUCA, 2006). Há autores que aconselham o não uso de filtros rejeita-faixa (POZZO; FARINA; MERLETTI,

2004), outros usam analogicamente ou o fazem em forma digital (CRISWELL, 2011). Merletti e Hermens (2004) afirmam que o não uso desses filtros é relevante quando os objetos de análise são as formas de onda do sinal, ao contrário de aplicações que utilizam parâmetros por amplitude ou potência do sinal (como em *biofeedback*).

Existem diversos estudos sobre qual é a banda aceitável para a captação do sinal de sEMG, os quais dependem da finalidade e da área de captação. Para análise de movimentos, os sistemas de filtragem se situam entre as faixas de 10 a 500 Hz (DE LUCA, 2006; POZZO; FARINA; MERLETTI, 2004). Para a captação de músculos faciais, recomenda-se a banda de 25-500 Hz, enquanto que de 100-200 Hz para o trapézio elimina ruídos provenientes da ação do coração (CRISWELL, 2011). Há trabalhos que utilizam frequências de corte para o passa-alta acima de 60 Hz e passa-baixa de até 250 Hz, os quais afirmam que o aumento da banda (tanto abaixo quanto acima) não representam grande acurácia em sistemas de classificação e de contribuem significativamente para a atenuação do sinal de 60 Hz (LI *et al.*, 2010, 2011). De uma forma generalizada, especificações das bandas dadas na literatura estão presentes na Figura 13.



**Figura 13 – Especificações gerais da banda esperada de frequências dos filtros de sEMG.**  
**Fonte: Autoria própria.**

Sobre a implementação dos filtros, estes podem ser construídos de forma analógica ou digital, por meio de *softwares* (SMITH, 1999). Os filtros analógicos podem ser passivos (com resistores, indutores e capacitores) quanto ativos (com a inserção de amplificadores operacionais). Estes últimos possuem uma menor quantidade de componentes que os primeiros, além de permitirem estágios de amplificação. Já os digitais, construídos por meio de *softwares*, são feitos pelas duas principais estruturas de filtragem: Resposta Finita ao Impulso (*Finite Impulse*

*Response*, FIR) e Resposta Infinita ao Impulso (*Infinite Impulse Response*, IIR). Estes últimos possuem as mesmas respostas que os sistemas em *hardware*, porém não possuem atraso conhecido nem resposta de fase linear, como os FIR (NALON, 2014; OPPENHEIM; SCHAFER, 1989). Estes filtros podem ser implementados por programas de desenvolvimento LabVIEW™ e MATLAB®.

### 2.3.5 Taxa de amostragem e conversão AD

Após o sinal estar adequadamente filtrado e amplificado, se é desejável que haja interação com um sistema digital (microcontrolador, computador, entre outros) então é necessário que o sinal seja amostrado e quantificado em um conversor Analógico-Digital (AD) (KAMEN; GABRIEL, 2015).

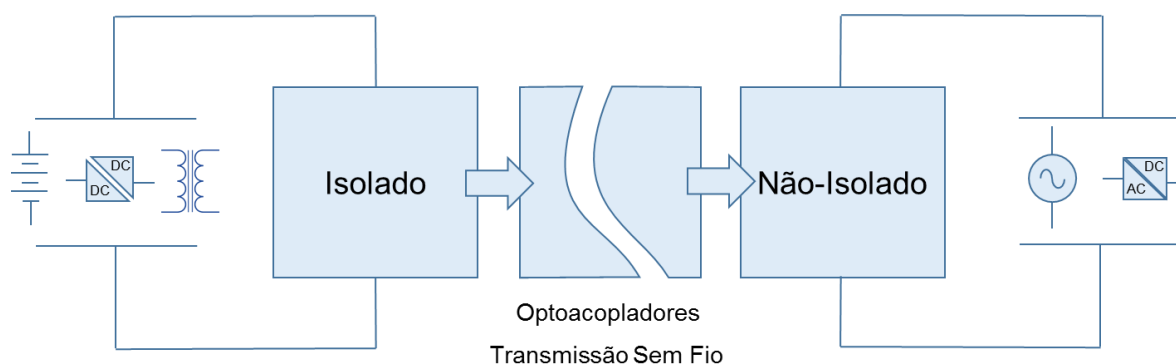
Geralmente o sinal de sEMG é amostrado em uma taxa de 1000 amostras por segundo, seguindo as orientações do Teorema de Nyquist, levando em consideração que as maiores frequências da banda se localizam entre 450-500 Hz (HAKONEN; PIITULAINEN; VISALA, 2015; MERLETTI; HERMENS, 2004). Antes da amostragem, é comum utilizar um filtro *anti-aliasing* para evitar o efeito de serrilhamento do sinal. Existem também trabalhos que utilizam menores taxas de amostragem (na faixa de 500 Hz) (LI *et al.*, 2011), reduzindo o processamento e a complexidade computacional.

O próximo passo é adequar a quantização do conversor AD. As faixas dinâmicas podem variar, mas as mais usuais estão entre  $\pm 5$  V e 0 a 10 V. Sobre a quantização, quanto maior a quantidade de bits, maior será a quantidade de níveis que poderão ser representados. Para sEMG são usadas altas resoluções, de 12 e 16 bits, a fim de garantir melhor detalhamento do sinal; porém, requerem maior poder computacional (KAMEN; GABRIEL, 2015; MERLETTI; HERMENS, 2004).

### 2.3.6 Isolação e Proteção

Comumente, os sistemas de captura de sEMG são divididos em duas partes devido a sua alimentação: isolada (ou flutuante) e não-isolada, apresentadas na Figura 14. A parte isolada do sistema é conectada ao indivíduo em que o sinal é capturado. Por isso, na parte isolada, os circuitos (com as funções de aquisição e condicionamento apresentados anteriormente) são alimentados por meio de baterias,

fontes/conversores CC-CC isolados e/ou conversores com isolamento por transformadores (MERLETTI *et al.*, 2009; OLSON, 2010). Em contrapartida, a parte não isolada é conectada em sistemas externos, de processamento e visualização de dados, como computadores, modems e osciloscópios. Para a alimentação desses equipamentos, é realizada a conexão direta com a rede de alimentação ou por meio de fontes que realizem a conversão AC-DC (MERLETTI *et al.*, 2009; OLSON, 2010).



**Figura 14 – Representação e alimentação das partes isoladas e não-isoladas dos sistemas de condicionamento do sinal de sEMG.**  
**Fonte: Autoria própria.**

Para oferecer segurança contra falhas elétricas, um sistema não pode ser ligado na rede elétrica de alimentação e no indivíduo sem nenhuma proteção. Barreiras de isolação, como optocopladores e sistemas de transmissão sem fio realizam a ponte entre as partes isoladas e não-isoladas, garantindo segurança ao indivíduo (MERLETTI *et al.*, 2009).

Por fim, realizadas todas as etapas de aquisição e condicionamento, o sinal é enviado para as posteriores etapas de processamento. Na seção seguinte, são destacados os sistemas que utilizam sEMG para comandar interfaces.

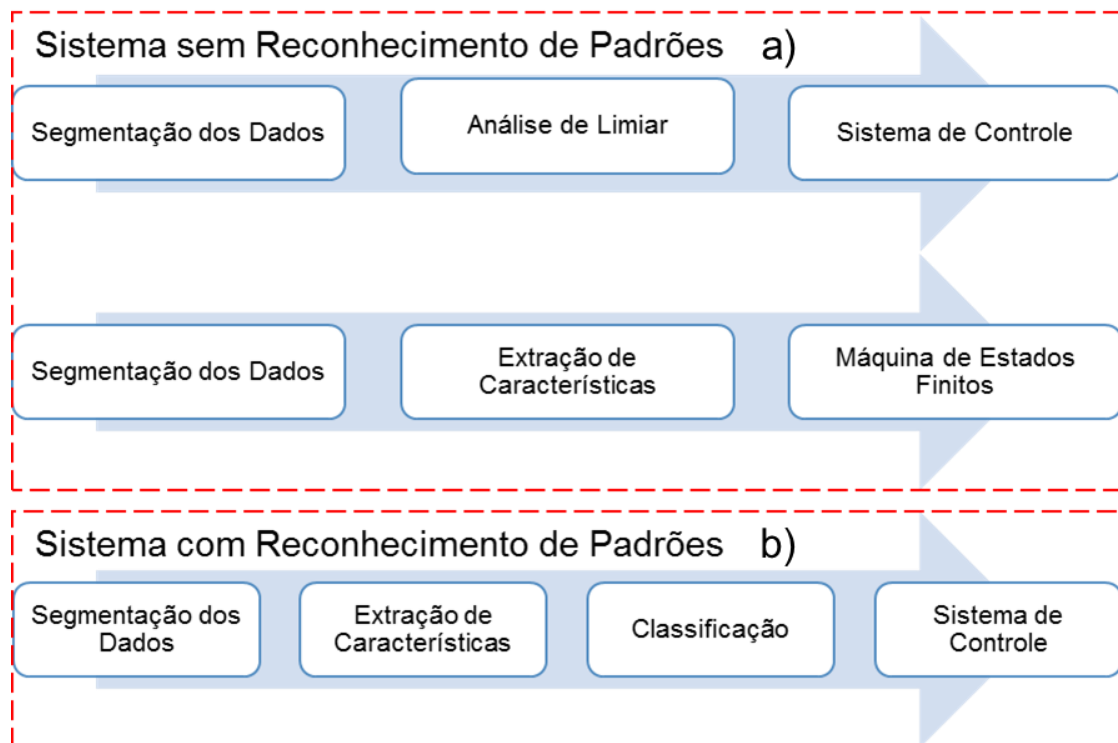
## 2.4 CARACTERÍSTICAS DOS SISTEMAS DE COMANDO POR EMG

De acordo com Englehart e Hudgins (2003), um sistema de controle que utilize sinais de sEMG precisa atender a três requisitos. O primeiro deles é a taxa de acerto do classificador sobre o movimento selecionado, a qual deve atingir patamares aceitáveis. O segundo ponto é conter uma interface intuitiva com o usuário para não o sobrecarregar de esforço. É preferível também que o sistema possa aprender as características do usuário durante o funcionamento para encontrar um padrão mais



natural de atuação. O terceiro requisito é possuir um tempo de resposta que não introduza um atraso muito grande na realização dos movimentos que seja perceptível pelo usuário, sendo esse o motivo da necessidade de implementação de modelos que trabalhem em tempo real durante a aquisição e o processamento (ENGLEHART; HUDGINS, 2003).

Os sistemas que utilizam sEMG para a realização atuação e controle de sistemas podem ser divididos em duas grandes grupos: os baseados em reconhecimento de padrões e os não baseados em reconhecimento de padrões (**Erro! fonte de referência não encontrada.**). Discutida por Oskoei e Hu (2007), cada abordagem é subdividida em etapas. Sistemas sem reconhecimento de padrões podem ser compostos por: segmentação de dados, análise de limiar e um sistema de controle para ativação de interfaces; ou segmentação de dados, extração das características de sEMG para o seu envio em uma máquina de estados finitos. Por outro lado, os sistemas com reconhecimento de padrões possuem também as etapas de segmentação de dados e extração de características, com o diferencial que estas características são enviadas a uma etapa de classificação para, então, serem aplicadas a um sistema de controle.



**Figura 15 – Classificação e estágios dos sistemas que utilizam o EMG para controle. a) sem reconhecimento de padrões; e b) com reconhecimento de padrões.**

Fonte: Oskoei e Hu (2007), adaptado.

De uma forma geral, os sistemas sem reconhecimento de padrões possuem como vantagens a simplicidade de implementação e a não necessidade de treinamento; porém, são limitados na quantidade de movimentos que conseguem manipular, com números restritos de posições. Por outro lado, os sistemas com reconhecimento de padrões fazem o cálculo de vetores contendo as características de fragmentos do sinal para usá-los em classificadores (HAKONEN; PIITULAINEN; VISALA, 2015).

#### 2.4.1 Segmentação dos dados


É comum a todos os tipos de sistemas de EMG possuir a etapa de segmentação dos dados, que consiste do uso de várias técnicas e métodos para manipular os sinais antes de enviá-los para a análise de suas características (OSKOEI; HU, 2007). Três elementos são analisados durante a segmentação dos dados: a técnica de janelamento do sinal, tamanho do segmento e estado do sinal de sEMG (HAKONEN; PIITULAINEN; VISALA, 2015; NAZMI *et al.*, 2016).

A técnica do janelamento pode ser de forma adjacente ou sobreposta. Na forma adjacente, segmentos ( $S_n$ ) são formados como o apresentado na Figura 16a, com tamanhos pré-definidos e seguidos de um atraso de tempo ( $t$ ) de processamento.

A técnica de sobreposição, ilustrada na Figura 16b, desconta o período de tempo de processamento, sobrepondo as janelas de segmentação. Quanto ao seu uso, leva-se em consideração que, no quesito atraso de tempo, sistemas com janelamento sobrepostos se destacam. Isso ocorre pois, enquanto novos dados são adquiridos, já se possui um valor processado (ENGLEHART; HUDGINS, 2003). Por outro lado, sobre a taxa de acerto no sistema de classificação, a adoção de do método de sobreposição não apresenta grande melhora nos resultados que o método adjacente, mas é significativa ao ser empregada em segmentos maiores que 200 ms para evitar atrasos no tempo (NAZMI *et al.*, 2016)-

O estado sinal de sEMG a ser segmentado pode pertencer a um estágio: transitório, correspondente da ativação das fibras desde o repouso até uma contração

voluntária; e permanente, que se mantém durante a contração do músculo, geralmente isométrica (OSKOEI; HU, 2007). Hudgins, Parker e Scott (1993) avaliaram pela primeira vez a informação contida no estágio transitório, apresentando que durante a fase inicial da contração, existem informações determinísticas que podem ser usadas em controles mioelétricos. O trabalho feito por Englehart, Hudgins e Parker (2001) endossou mais as informações sobre essa área, afirmando que os dados do estado permanente podem ser classificados com maior taxa de acerto que em estado transitório. Os autores propuseram que um valor pequeno de segmento, como 128 ms, no estado permanente seria mais confiável para um rápido desempenho de um sistema como todo.



**Figura 16 – Métodos de técnica de janelamento da segmentação dos dados, em que a) representa a abordagem adjacente e b) a abordagem sobreposta.  $S_n$  representa cada segmento extraído e  $t$  o atraso do processamento.**

**Fonte: Autoria própria.**

Por fim, um dos parâmetros mais importantes é a escolha do tamanho do segmento. Grandes janelas aumentam a eficácia da classificação mas requerem maior tempo de coleta e computação (NAZMI *et al.*, 2016). Entre os autores, há o consenso de que para controles, atrasos maiores que 300 ms podem apresentar problemas na execução dos movimentos (ENGLEHART; HUDGINS, 2003). Oskoei e Hu (2008) demonstraram que é possível o uso de segmentos menores que 200 ms para a estimação de movimentos, podendo aumentar o tempo de processamento computacional. Dessa forma, é possível encontrar trabalhos que utilizam valores entre 32 a 250 ms (OSKOEI; HU, 2007).

#### 2.4.2 Extração de características

Passadas as etapas de condicionamento e segmentação, o sinal de sEMG ainda se classifica como bruto (em inglês, *raw*), pois nenhuma informação relevante foi retirada de seu meio. O uso de dados sem processamento leva a classificadores ou sistemas de controle a um decréscimo de sua eficiência (CHOWDHURY *et al.*, 2013). Além de ser uma questão para uma melhora do desempenho, muitas vezes é impraticável alimentar um determinado classificador com um alto número de entradas (OSKOEI; HU, 2007). A título de exemplo, se um segmento contendo um período de tempo de 250 ms que foi amostrado com uma frequência de 2000 amostras/segundo fosse usado em um classificador, este deveria conter 500 entradas. Estes dados podem ser processados a fim de se extrair um número muito menor de informações que representem essa parcela do sinal. A essas informações dá-se o nome de características. As características podem ser classificadas em quatro categorias, de acordo com: o domínio do tempo; o domínio da frequência (ou espectral); o domínio tempo-escala ou tempo-frequência e; o domínio espacial.

A análise de características no domínio do tempo é baseada na alteração da amplitude do sinal no decorrer do tempo, sendo computadas de forma mais simples mas mais sensíveis as interferências e artefatos de movimento. Por outro lado, as características de frequência possuem a densidade do espectro de potência, sendo computadas por meio de periodogramas ou métodos paramétricos (NAZMI *et al.*, 2016). O domínio de tempo-frequência combina informações disponíveis nas duas classes anteriores de forma a caracterizar a variação da informação da frequência em diferentes localizações de tempo. Por fim, as informações do domínio espacial concentram-se na distribuição das PAUMs e seus disparos, envolvendo análises de regiões musculares (HAKONEN; PIITULAINEN; VISALA, 2015).

Neste trabalho, estão contidas e são explanadas as características no domínio do tempo a fim de restringir a quantidade de informações. As características de frequência, de tempo-frequência/tempo-escala e medições de sEMG de alta dimensão utilizam ferramentas como Transformadas de Fourier, Transformadas de Tempo-Frequência e Transformadas Wavelets, conceitos estes que não são abordados no estágio atual da pesquisa.

Hudgins, Parker e Scoot (1993) estudaram cinco características de EMG para o uso em controles de próteses. Em seu trabalho, os autores exploraram o uso da

Média do Valor Absoluto (em inglês, *Mean Absolute Value*, MAV), Gradiente da Média do Valor Absoluto, Cruzamento de Zeros, Mudança do Sinal do Gradiente e Comprimento de Onda. Entre as vantagens dessas características, destacam-se a alta taxa de acerto de classificação, estabilidade contra alteração do tamanho do comprimento da onda e simplicidade computacional (HUDGINS; PARKER; SCOTT, 1993; OSKOEI; HU, 2008).

É importante ressaltar o trabalho realizado por Phinyomark, Phukpattaranont e Limsakul (2012) que reuniram as características de tempo e de frequência, somando 37 ao total – 26 de tempo e 11 de frequência -, mais usadas para o processamento de sEMG. Por meio de análises estatísticas e do resultado de classificadores, os autores apontaram que existem características com informações redundantes (PHINYOMARK; PHUKPATTARANONT; LIMSAKUL, 2012). **A Erro! Fonte de eferência não encontrada.** apresenta as principais características que podem ser usadas para analisar o sinal de sEMG.

**Tabela 1 – Principais características que podem ser extraídas do sinal de EMG, suas equações e considerações.**

Característica	Equação Matemática	Considerações
Integral ( $I_{EMG}$ )	$I_{EMG} = \sum_{n=1}^N  x_n $ <p>Onde N é o comprimento do sinal e <math>x_n</math> representa o sinal de EMG</p>	(10) Definido como a soma de todos os valores absolutos do sinal, a Integral do sinal é usada para detectar o índice de presença do sinal em sistemas sem reconhecimento de padrões.
Média do Valor Absoluto (MAV)	$MAV = \frac{1}{N} \sum_{n=1}^N  x_n $	(11) É uma das características mais populares, especialmente nos trabalhos que utilizam sEMG para controle de próteses.
Integral simples quadrática ( <i>Simple Squared Integral</i> , SSI)	$SSI = \sum_{n=1}^N x_n^2$	(12) A SSI também é definida como o índice de energia do sinal de EMG.
Variância do EMG (VAR)	$VAR = \frac{1}{N-1} \sum_{n=1}^N x_n^2$	(13) É uma das características que indica potência do sinal
Raiz quadrada média ( <i>Root Mean Square</i> , RMS)	$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2}$	(14) A RMS é um dos parâmetros mais populares, relacionada a força constante e contrações não-fatigadas.
Comprimento de Onda ( <i>Waveform Length</i> , WL)	$WL = \sum_{n=1}^N  x_{n+1} - x_n $	(15) Mensurado como o comprimento cumulativo do sinal de EMG no tempo, é considerado a medida da complexidade do sinal de EMG.

**Fonte: Autoria própria.**

### 2.4.3 Sistemas sem reconhecimento de Padrões (Análise de Limiar e Máquinas de Estados Finitos)

Tendo os dados segmentos e/ou retiradas as suas características, inicia-se o processo de tomada de decisão nos sistemas sem reconhecimento de padrões. Estes utilizam como estratégia para o controle miográfico as técnicas de controle proporcional, análise de limiar (*threshold*) ou *onset*, e máquinas de estados finitos. A natureza desse tipo de aplicação está contida em controles limitados, muito utilizados em comandos de Liga-Desliga (*ON-OFF*), interfaces intuitivas para menus de navegação, cadeiras de rodas, robôs assistivos, próteses e exoesqueletos (HAKONEN; PIITULAINEN; VISALA, 2015; OSKOEI; HU, 2007).

A análise de *onset* avalia a ativação e desativação muscular pelo tempo. Para isso, dois métodos principais são adotados: o limiar simples (ou único) ou o duplo linear (ou duplo *threshold*).

No método de *threshold* simples, os sinais de sEMG são retificados e comparados com um valor de limiar (muitas vezes sendo a MAV do próprio sinal). Quando se atinge um valor igual ou maior o determinado, é disparado um sinal booleano indicando essa ultrapassagem. É muito comum que o sinal seja filtrado por um passa-baixa antes de entrar no comparador para deixar a resposta mais suavizada, chamado de *smoothing*. As vantagens desse método são a sua rapidez de processamento e sua simplicidade ao ser montado; porém, mesmo com o *smoothing*, ainda é muito sensível ao ruído e altamente dependente do valor de limiar (HAKONEN; PIITULAINEN; VISALA, 2015).

O segundo método, o duplo *threshold* (também conhecido como histerese), foi desenvolvido para reduzir a dependência do valor do limiar no sistema de simples *threshold*. Utilizado por Bonato, D'alessio e Knaflitz (1998), esse método evita que falsos alarmes possam ocorrer no sinal, o que leva ao sistema sofrer repiques. Para evitá-los, o duplo *threshold* analisa tanto o tempo quanto o valor obtido na primeira análise. (BONATO; D'ALESSIO; KNAFLITZ, 1998). No duplo *threshold* há uma suavização dos valores obtidos em relação ao *threshold* simples. Entretanto, este método possui um certo custo computacional e complexidade agregada. Xu e Adler (2004) melhoraram o método de duplo *threshold*, tornando o mais sensível com baixo custo computacional.

Por conseguinte, os sistemas que utilizam máquinas de estado finito usam um número determinado de estados (transições), com comandos pré-definidos dos dispositivos, muito usados para comandos de cadeiras de rodas e robôs com grande taxa de acerto. Um dos exemplos mais clássicos é o sistema desenvolvido por Felzer e Freisleben (2002) para uma cadeira de rodas motorizada comandada por músculos na região da frente. Com os dados de duplo *threshold* inseridos em uma máquina de estados finitos, Moon *et al.* (2005) comandaram outra cadeira de rodas usando os músculos do ombro.

#### 2.4.4 Classificação (Reconhecimento de Padrões)

De forma diferente do que foi apresentado anteriormente, os sistemas com reconhecimento de padrões utilizam uma etapa de classificação, o que permitem atingirem um maior número de graus de liberdade e classes. Nessa etapa, os valores de entrada são reconhecidos em gestos, movimentos ou ações, os quais são previamente introduzidos em uma seção de treinamento. O classificador deve consumir a menor quantidade de tempo possível visando atingir os parâmetros e restrições de aplicações em tempo real. Sabe-se também que essa etapa é fortemente dependente das características extraídas do sinal, pois um conjunto apropriado de informações de sinais de EMG pode facilitar a classificação, fazendo com que o sistema se assemelhe a um problema linear (HAKONEN; PIITULAINEN; VISALA, 2015; OSKOEI; HU, 2008).

Vários tipos de classificadores são usados, como Redes Neurais Artificiais, abordagem Fuzzy e Neuro-Fuzzy, Análise dos Discriminantes Lineares (do inglês, *Linear Discriminant Analysis*, LDA), Mapas Auto-Organizáveis e Máquinas de Suporte Vetoriais (BALBINOT; FAVIEIRO, 2013; CHOWDHURY *et al.*, 2013).

Dentre os classificadores, destacam-se as RNAs, que são utilizadas nesse trabalho. As RNAs possuem a capacidade de representar tanto funções lineares quanto não lineares além de aprenderem a relação que existe entre a saída e a entrada por uma etapa de treinamento com os próprios conjunto de dados. Pode-se destacar o trabalho de Hudgins, Parker e Scott (1993) como um dos pioneiros a utilizar uma Perceptron de Múltiplas Camadas (ou *Multi-Layer Perceptron*, MLP) para classificar sinais de EMG com as características extraídas previamente citadas.

Porém, trabalhos recentes, como de Zhao *et al.* (2006) e Ahsan, Ibrahimy e Khalifa (2011), ao utilizarem esse mesmo método de classificação, conseguiram taxas de acertos entre 85 a 95%.

O método de RNAs para classificação é utilizado com grande diversidade. Au e Kirsch (2000) desenvolveram uma rede neural com topologia de atraso (do inglês, *Time-Delayed Artificial Neural Network*, TDANN) que predizia o sinal de EMG e o usava para classificar em outra rede a fim diminuir o tempo de aquisição e processamento. Trabalhos com redes neurais híbridas ou adaptativas também são construídas para a classificação destes dados e são apontadas como grandes expoentes para trabalhos futuros nessa área (XIE *et al.*, 2014). Como exemplo, pode-se citar os trabalhos de Khezri e Jahed (2007), com uma rede Neuro-Fuzzy adaptativa para a classificação de EMG; e Balbinot e Favieiro (2013), com uma rede Neuro-Fuzzy com a média das taxas de acerto de 86% para 7 movimentos distitos.

Entretanto, a abordagem de RNA possui algumas limitações. Estas limitações referem-se principalmente a precisão da saída, que é limitada no treinamento a funções que resultem em erros quadráticos médios, além de possuírem longo tempo de treinamento e necessitarem que todas as classes de saídas devem ser apresentadas no conjunto de treinamento para serem reconhecidas (XIE *et al.*, 2014).

#### 2.4.5 Sistema de Controle

Os sistemas de controle que utilizam sEMG estão diretamente ligados às aplicações a eles relacionadas. Cada aplicação final possui um sistema físico (como próteses, exoesqueletos e robôs), interface (computadores e sistemas inteligentes microprocessados) e *software* (como de reconhecimento e monitoramento, por exemplo) próprio. Dessa forma, existem diversos sistemas eletroeletrônicos, formas mecânicas e funções de programação próprios.

Em próteses e robôs, comumente as aplicações estão vinculadas ao comando das juntas do cotovelo e do pulso; e como ferramentas e membros, os movimentos do pulso, da mão, do antebraço e dos membros (OSKOEI; HU, 2007). Nas tecnologias assistivas, são criadas cadeiras de rodas elétricas, exoesqueletos para reabilitação, robôs e até jogos desenvolvidos para a melhorar a condição física e distrair a dor do paciente. Por fim, outras aplicações são destinadas ao uso de sEMG como entrada



para sistemas, como é o caso das *armbands*, das interfaces diretas para o computador e em sistemas de reconhecimento silencioso de voz (HAKONEN; PIITULAINEN; VISALA, 2015).

Ao final da apresentação das principais técnicas de processamento de sEMG, percebe-se que há uma grande quantidade de trabalhos e ferramentas que podem usadas para diversas aplicações. Com o foco na aplicação desenvolvida, nas seções seguintes são discorridos sobre o conceito de fusão de sensores (presente no desenvolvimento do *hardware*) e sobre o método de classificação utilizado neste trabalho, composto por Redes Neurais Artificiais.

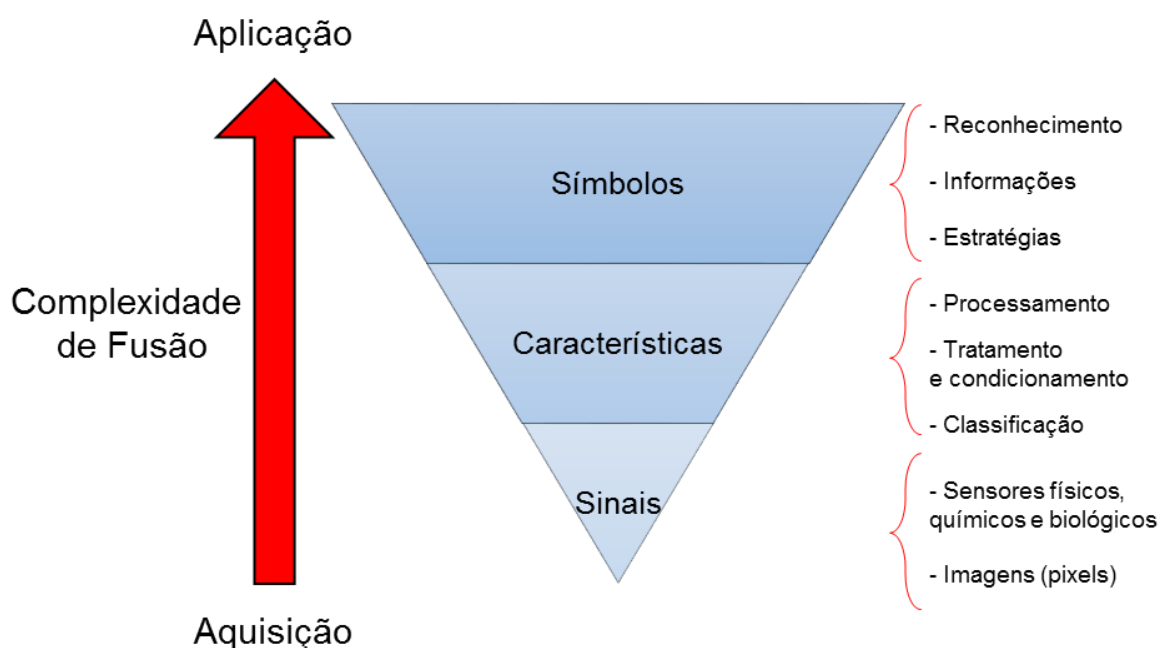
## 2.5 FUNDAMENTOS SOBRE FUSÃO DE SENSORES

A fusão de sensores é considerada a combinação de dados de diferentes sensores, os quais podem resultar em inferências mais complexas que não são possíveis com uso de sensores de forma individual e/ou separada (LUO; CHANG, 2012). Essa técnica inclui a aquisição dos dados de diferentes variáveis e grandezas, o gerenciamento e a associação destes dados com estratégias capazes de fornecer resposta consistentes e eficazes (LUO; CHANG; LAI, 2011). O gerenciamento das informações também aborda a incerteza dos sensores (que estão relacionados aos ruídos do sistema, do meio e do próprio sensor) e modelagens dinâmicas do comportamento das variáveis (LUO; CHANG; LAI, 2011).

A fusão de sensores requer uma compreensão multidisciplinar em diversas áreas, como processamento de sinais, estatística, probabilidade, teoria de controle e inteligência artificial (LUO; CHANG; LAI, 2011). Dentre as suas aplicações, se destacam a detecção de falhas, sistemas de comunicação (especialmente sem fio), mineração de dados, detecção de trajetória, de imagem, e sistemas biomédicos (AZIZ, 2014).

Existem determinados níveis de fusão e há conceitos similares com propostas diferentes, especificadas em duas situações. A primeira é a fusão de sensores feitos com sinais diferentes (a qual se caracteriza como fusão de sensores), enquanto que a segunda ocorre quando não há presença de grandezas diferentes, mas de sensores equivalentes em situações diferentes (a qual trata-se de fusão de dados de sensores) (AZIZ, 2014).

Tradicionalmente, a arquitetura da fusão de sensores é composta por três níveis após a aquisição até a aplicação final: fusão de sinais dos sensores, fusão de características e fusão de símbolos ou decisões, conforme ilustrado na Figura 17 (MENDES JR. *et al.*, 2016). O primeiro nível, correspondendo ao mais baixo, é composto pelos diferentes sensores que coletam sinais de  $n$  variáveis. Nesta etapa, são fundidos os sinais que provêm de sensores ou câmeras, que captam grandezas físicas, químicas e biológicas ou pixels, respectivamente. No segundo nível, encontra-se a fusão de características, em que fundem-se técnicas de processamento e de tratamento do sinal, envolvendo condicionamento e classificação de dados. Por meio dessas fusões, extraem-se as principais informações do sinal. Com essas informações, por fim, há o terceiro nível de fusão, chamado nível de símbolos. Nesse nível, ocorre o gerenciamento dos dados obtidos, o que envolve a fusão de reconhecimento da informação, de informações e estratégias na aplicação (LUO; CHANG, 2012).



**Figura 17 – Representação dos níveis de fusão de sensores.**  
**Fonte: Mendes Junior *et al.* (2016), adaptado.**

Dentre a enorme possibilidade de fusões, o uso de sensores inerciais com sEMG é amplamente aplicado em reabilitação e reconhecimento de sinais. Entre alguns destes trabalhos recentes, destacam-se: Senanayake *et al.* (2013), que correlaciona dados de sEMG com sensores inerciais para avaliar o processo de

recuperação muscular, Spulber *et al.* (2014), que com mais um sensor polimérico flexível para auxiliar na recuperação da junta do joelho; Martin *et al.* (2014), que com a adição de uma câmera para detecção de movimentos desenvolveu um método de comando de prótese mais eficiente que apenas o uso de sEMG; Artemiadis e Kyriakopoulos (2011) e sua metodologia para comando de atuadores robóticos, chamada de *tracking*; e Zhang *et al.* (2011) que utiliza sinais de sEMG e sensores inerciais distribuídos no braço para reconhecimento de 72 palavras do alfabeto chinês de linguagem de sinais.

### 2.5.1 Sensores Inerciais

Os sensores inerciais são instrumentos bases da navegação inercial, compostos basicamente por acelerômetros e giroscópios. Com o surgimento dos circuitos integrados, a tecnologia chegou até os chamados Sistemas Micro-Eletromecânicos (MEMS, do inglês, *Micro-Electro-Mechanical Systems*), implementados em uma pastilha/*chip* eletrônico (CARVALHO, 2011). De forma mais barata, os sistemas inerciais em MEMS possuem as seguintes vantagens, que são o seu tamanho reduzido e baixo custo.

Acelerômetros capacitivos e piezoelétricos são dispositivos usados para a medição de inclinação e aceleração, também chamada de força específica (para diferenciar da aceleração gravitacional). Geralmente, os acelerômetros são constituídos por uma massa de reação suspensa por uma estrutura estacionária, podendo ser medida de forma capacitiva, resistiva, piezoelétrica ou microeletrônica. Seu funcionamento é baseado na segunda lei de Newton, em que a força (exercida pelo corpo suspenso) é o produto entre a massa do corpo e sua aceleração (COLLIN *et al.*, 2013; GREWAL; WEILL; ANDREWS, 2007; STEVAN JR.; SILVA, 2015).

Os giroscópios são sensores que medem velocidade angular ao longo de um eixo. São utilizados para auxiliar sistemas de estabilização e informar alterações na direção e orientação. Como não possuem referência fixa, são aptos para medir alterações de estado (COLLIN *et al.*, 2013; STEVAN JR.; SILVA, 2015).

Em uma Unidade de Medição Inercial (IMU, do inglês, *Inertial Measurement Unit*) podem estar combinados múltiplos acelerômetros e giroscópios para a medição de aceleração linear e velocidade angular, respectivamente (COLLIN *et al.*, 2013;

GREWAL; WEILL; ANDREWS, 2007). É comum encontrar em sistemas IMUs acelerômetros e giroscópios triaxiais (de três eixos). Sobre seus sistemas de condicionamento, cada tipo de sensor (resistivo, capacitivo e piezoelétrico) possui um circuito próprio. Por outro lado, IMUs em formato MEMS possuem saídas digitais em protocolos de comunicação como I<sup>2</sup>C (Circuito Inter-Integrado, do inglês *Inter-Integrated Circuit*) e SPI (Interface Serial de Periféricos, do inglês *Serial Peripheral Interface*).

Existem certos fatores que devem ser analisados em relação aos erros contidos nos sistemas inerciais durante a medição de seus sinais. Entre eles, destacam-se: o erro de *bias* (caracterizado pela média de sua saída quando ele não está sujeito a nenhuma movimentação); erro de quantização (erro da diferença de tempo entre a amostra ser captada e disponível na saída do sensor); efeitos de temperatura (o qual pode induzir aumento no erro de *bias*); e erro de calibração (erros de escalas e linearidades do sensor). Por isso, é necessário analisar também as suas características, como faixa de medição (ou *range*, sendo os limites de leitura), sensibilidade e não-linearidade. Muitas vezes, são aplicados filtros digitais diretamente na saída dos dados para aumentar a robustez do sinal, atenuar os ruídos e suavizar a sua forma de onda, para então aplicar-se processamentos para extração das variáveis por ele derivadas (CUARELLI, 2013; MORI, 2013).

## 2.6 REDES NEURAIS ARTIFICIAIS

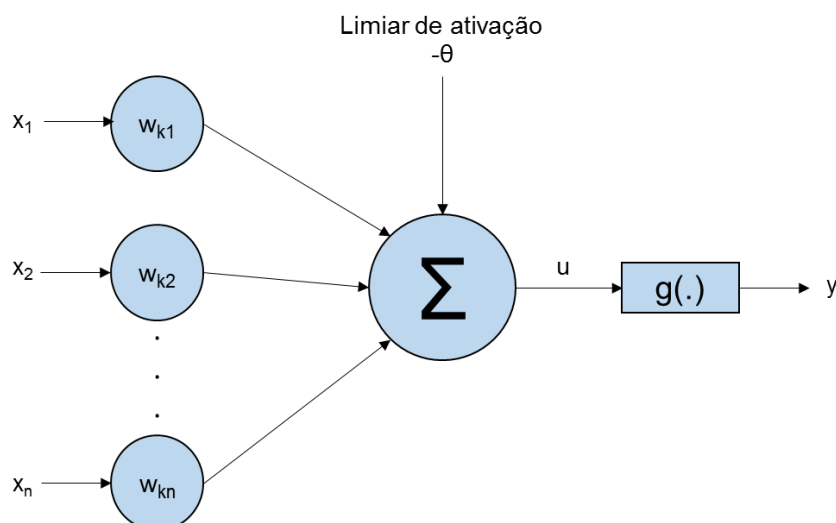
De acordo com Silva, Spatti e Flauzino (2010) uma RNA é um modelo computacional inspirado no sistema nervoso dos seres vivos, podendo adquirir e manter o conhecimento, sendo consideradas uma unidade de processamento. Uma RNA é composta por neurônios artificiais interligados por meio de interconexões entre vetores e matrizes de tal forma que representam sinapses artificiais.

Entre as características principais de uma RNA, destacam-se:

- a sua adaptação por experiência, em que os valores dos pesos sinápticos são ajustados pela apresentação sucessiva de informações;
- capacidade de aprendizado, pois com uma etapa de treinamento, a rede obtém o relacionamento entre as variáveis de entrada e saída;

- habilidade de generalização, mesmo sem possuir uma determinada amostra desconhecida, a rede pode aproximar para uma solução e “aprender” com esse processo e;
- facilidade de prototipagem, por a implementação pode ser feita em diversos sistemas em *hardware* e *software* (HAYKIN, 2001; SILVA; SPATTI; FLAUZINO, 2010).

O modelo básico de uma RNA é o neurônio artificial, apresentado na **Erro! fonte de referência não encontrada.** A modelagem foi desenvolvida por Mcculloch e Pitts (1943) baseada na Lei do Tudo ou Nada, e pela sua simplicidade, é adotado até os dias atuais. Os sinais de entrada são representados por  $x_1$ ,  $x_2$  até  $x_n$  e correspondem aos dendritos celulares, sendo que  $n$  é o número da quantidade de entradas. As ligações entre a entrada e o corpo celular são representados pelos pesos sinápticos  $w_{k1}$ ,  $w_{k2}$  e  $w_{kn}$ . Cada valor inserido na entrada é multiplicado pelo seu peso sináptico correspondente. Todas a multiplicações são somadas, o qual corresponde a ação do corpo celular que recebe e cria uma resultante dos sinais recebidos. O valor somado é subtraído de um limiar de ativação ( $\theta$ ), que consta de uma grandeza usada para gerar um valor de disparo à saída do neurônio, representado por  $u$ . Esse resultado ( $u$ ) também é chamado de potencial de ativação e é a entrada da função de ativação. A função de ativação,  $g(\cdot)$ , limita a saída do neurônio em um determinado intervalo de valores correspondes a imagem dessa função. Por fim, o sinal de saída ( $y$ ) é o valor final produzido pelo neurônio, podendo tanto ser a entrada de um próximo neurônio ou o valor final da RNA. Essas últimas ações são comparáveis às do axônio, que redistribui a informação processada (MCCULLOCH; PITTS, 1943; SILVA; SPATTI; FLAUZINO, 2010).



**Figura 18 – Modelo de neurônio artificial.**  
**Fonte: Autoria própria.**

De uma forma simplificada, (16) e (17) são as equações do modelo proposto por Mcculloch e Pitts (1943):

$$u = \left( \sum_{j=1}^n w_{kj} \cdot x_j \right) - \theta \quad (16)$$

$$y = g(u) \quad (17)$$

em que:

$u$  representa o potencial de ativação;

$w_{kj}$  representa o peso sináptico correspondente a  $j$ -ésima ligação;

$x_j$  representa os valores de entrada da rede neural até a  $j$ -ésima entrada;

$\theta$  representa o limiar de ativação;

$g(u)$  representa a função de ativação; e

$y$  representa a saída da rede neural.

A informação e o conhecimento da RNA estão concentrados nos valores dos pesos sinápticos. A fim de melhorar os algoritmos da construção de redes, o valor do limiar de ativação é considerado como um peso sináptico (representado por  $w_{k0}$ ). As funções de ativação podem ser classificadas entre parcialmente diferenciáveis (função degrau, degrau bipolar e rampa simétrica) e diferenciáveis (função logística, tangente hiperbólica, linear e gaussiana). As funções parcialmente diferenciáveis são mais usadas nas primeiras topologias de redes, como a *Perceptron* e *Adaline*, enquanto

que diferenciáveis são aplicadas em Perceptron de Múltiplas Camadas (MLP), Redes de Base Radial (RBF), entre outras (HAYKIN, 2001; SILVA; SPATTI; FLAUZINO, 2010) .

O processo de aprendizagem ou treinamento é um dos mais importantes nesse sistema inteligente. De forma conceitual, o treinamento é o processo de atualização da informação (no caso, dos pesos sinápticos) que representa a resposta do sistema um estímulo externo a ele apresentado (BASHEER; HAJMEER, 2000). Essa etapa de treinamento pode ser feita de forma supervisionada - em que os dados são apresentados com as respectivas saídas - ou não-supervisionada - em que a rede encontra uma solução com os dados apresentados pela proximidade entre ele, os quais não possuem saídas com valores determinados (SILVA; SPATTI; FLAUZINO, 2010).

### 2.6.1 Perceptron de Múltiplas Camadas (MLP)

Uma MLP é uma variante da Perceptron de uma camada e possui a presença de ao menos uma camada intermediária, também chamada de camada de neurônios escondidos. Essa camada é uma obrigatoriedade da rede, ou seja, é necessária uma camada oculta que não faça parte da camada de entrada ou de saída da rede (BASHEER; HAJMEER, 2000). A grande característica dessa topologia de rede é a sua alta aplicabilidade e flexibilidade de funções. Encontram-se MLPs em sistemas de processamento de sinais, aproximação de funções, previsão de séries temporais e reconhecimento/classificação de padrões (SILVA; SPATTI; FLAUZINO, 2010).

A arquitetura é *feedforward*, com a informação sendo passada em apenas um sentido. O seu treinamento é feito de forma supervisionada por meio do algoritmo de *backpropagation*, o qual deseja-se localizar o mínimo global ou local da função do erro entre a entrada e a saída (GARDNER; DORLING, 1998). Este algoritmo é composto de duas fases: *forward* e *backward*. Na *forward*, os sinais de uma amostra são inseridos na entrada e propagados de camada a camada até a saída. Em função da saída e o valor desejado, obtém-se o erro e os pesos sinápticos são ajustados das camadas mais próximas da saída até a camada de entrada: esta é a fase *backward* executada no treinamento.

Para que a ação da MLP não se reduza a uma Perceptron de uma camada, há a necessidade de que seja usada uma função que seja diferenciável e com fator

de não-linearidade suave. Por isso, a função logística e tangente hiperbólicas são usadas como funções de ativação (HAYKIN, 2001; SILVA; SPATTI; FLAUZINO, 2010).

O modelo de arquitetura de uma MLP é apresentado na Figura 19. Nesse exemplo, a MLP contém três camadas: uma camada de entrada de  $n$  dados; uma camada escondida com quantidade de  $n_1$  neurônios; e uma camada de saída com  $n_2$  neurônios. Nesse exemplo, a multiplicação entre os dados da entrada com os pesos sinápticos  $W_1$  resultam em um vetor  $I_1$ , que é a entrada da camada escondida. Cada flecha representa uma conexão sináptica, e em cada uma, um valor escalar correspondente ao peso sináptico. Os dados passam pela função de ativação (que na ilustração de exemplo é a tangente hiperbólica) em um vetor denominado  $Y_1$ . Este vetor é multiplicado por um novo conjunto de pesos sinápticos,  $W_2$ , os quais dão origem a um vetor  $I_2$ . Novamente existe um limiar de ativação para cada neurônio, representado pelo valor -1. Por sua vez, os dados do vetor  $I_2$  são a entrada da camada de saída, composta por  $n_2$  neurônios com uma função de ativação logística. Cada neurônio da camada de saída fornece um determinado valor, os quais compõe o vetor de saída  $Y_2$ .

Matematicamente, utilizando ainda a Figura 19 como exemplo, o comportamento da MLP pode ser avaliado na etapa *forward* por meio da equação (18)

$$\mathbf{Y}_2 = g_2(g_1(\mathbf{X} \times \mathbf{W}_1^T) \times \mathbf{W}_2^T) \quad (18)$$

em que:

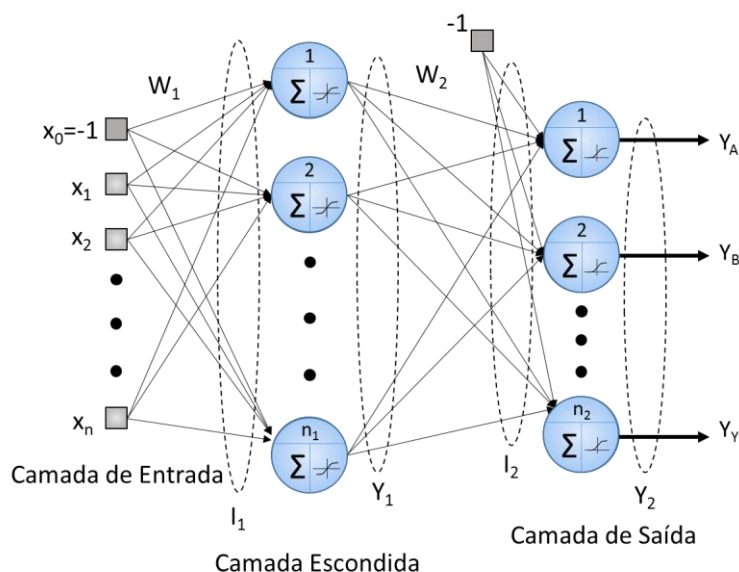
$\mathbf{Y}_2$  representa o vetor de saída da rede neural;

$g_1$  e  $g_2$  representam as funções de ativação tangente hiperbólica e logística, respectivamente.

$\mathbf{X}$  representa os vetores dos dados de entrada; e

$\mathbf{W}_1^T$  e  $\mathbf{W}_2^T$  representam as matrizes de pesos sinápticos transpostos.





**Figura 19 – Arquitetura de uma MLP.**  
**Fonte: Autoria própria.**

Além destas variáveis, é necessário reafirmar que o produto entre os vetores  $\mathbf{X}$  e  $\mathbf{W}_1^T$  resultam em  $\mathbf{I}_1$ , que ao passarem pela função de ativação  $g_1$ , tornam-se  $\mathbf{Y}_1$ . Por conseguinte,  $\mathbf{Y}_1$  multiplicado vetorialmente por  $\mathbf{W}_2^T$  resulta em  $\mathbf{I}_2$ .

No treinamento, como os pesos são ajustados pela etapa *backward*, o processo inicia-se pela camada de saída. Um dos métodos mais usados para a minimização do erro é o do gradiente (GARDNER; DORLING, 1998). A sua implementação segue a seguinte sequência de passos (BISHOP, 1995; SILVA; SPATTI; FLAUZINO, 2010):

- Passo 1. Inicializar os pesos sinápticos da rede. É desejável que estes valores sejam randômicos e pequenos (GARDNER; DORLING, 1998).
- Passo 2. Apresenta o primeiro vetor dos valores de entrada do treinamento e propagar até o fim da rede para obter um valor na saída;
- Passo 3. Calcular o erro do sinal pela comparação entre o sinal obtido na saída com o desejado. Como está sendo usado o método do gradiente, o gradiente local do erro da camada de saída pode ser obtido pela equação (19):

$$\delta_2 = (\mathbf{d} - \mathbf{Y}_2) \times g'(\mathbf{I}_2) \quad (19)$$

em que:

- $\delta_2$  representa o vetor/matriz do gradiente local do erro da camada de saída;
- $\mathbf{d}$  representa o vetor/matriz da saída desejada e;

$g'()$  representa a função da derivada da função de ativação. Aqui encontra a necessidade que seja utilizada uma função de ativação inteiramente diferenciável.

Passo 4. Por meio do gradiente, é calculado os pesos sinápticos entre a camada escondida e a camada de saída é dada pela equação (20):

$$\mathbf{W}_2 = \mathbf{W}_2 + \eta \times \delta_2 \times \mathbf{Y}_2 \quad (20)$$

em que:

$\eta$  representa a taxa de aprendizagem.

Passo 5. O próximo passo é o cálculo do vetor/matriz gradiente ( $\delta_1$ ) correspondente a camada escondida e a camada de entrada, dado pela equação (21)

$$\delta_1 = (\delta_2 - \mathbf{W}_2) \times g'(\mathbf{I}_1) \quad (21)$$

Passo 6. Com o valor do gradiente, os pesos sinápticos de  $\mathbf{W}_1$  são ajustados pela equação (22)

$$\mathbf{W}_1 = \mathbf{W}_1 + \eta \times \delta_1 \times \mathbf{X} \quad (22)$$

Passo 7. Como critério de parada, é mensurado o valor do erro entre a saída desejada e a saída obtida. Sendo  $p$  a quantidade de amostras, o erro quadrático médio pode ser medido pela equação (23)

$$E_M = \frac{1}{p} \sum \left( \frac{1}{2} \sum (\mathbf{d} - \mathbf{Y}_2)^2 \right) \quad (23)$$

Passo 8. Até se obter um valor de erro aceitável, os passos de 2 ao 8 são repetidos.

A parada da execução do algoritmo *backpropagation* pode ser feita pelo valor do erro ou pelo número de épocas de treinamento, ou seja, por cada iteração em que o algoritmo foi executado. Ao ser feito pelo valor do erro, usualmente é analisada a precisão do erro quadrático, medido pela diferença entre o erro atual com o erro anterior. Se este for menor ou igual a precisão, o algoritmo encerra o seu treinamento.

Entretanto, é necessário tomar certa atenção ao estabelecer um critério de parada para o treinamento a fim de não inibir o processo de generalização dos dados da rede neural. Ou seja, deve-se haver cuidado para que a rede não fique específica apenas para o conjunto de dados apresentados e se perca quando for apresentado um dado diferente dos padrões apresentados – efeito denominado *overfitting* (SILVA; SPATTI; FLAUZINO, 2010).

Geralmente, as topologias são propostas para analisar qual possui melhor desempenho frente aos dados a serem classificados. Uma das questões importantes é o número de neurônios das camadas escondidas. Não existe uma determinada regra, os valores são definidos empiricamente. Existem alguns critérios que podem auxiliar no desenvolvimento das topologias (SILVA; SPATTI; FLAUZINO, 2010). O primeiro deles, o de Kolmogorov, utiliza a regra dada pela equação (24)

$$n_1 = 2n + 1 \quad (24)$$

em que:

$n_1$  representa o número de neurônios da camada escondida; e  
 $n$  representa o número de entradas da rede.

O segundo deles, utilizado na plataforma Weka, apresenta como critério a equação (25)

$$n_1 = \frac{n + n_c}{2} \quad (25)$$

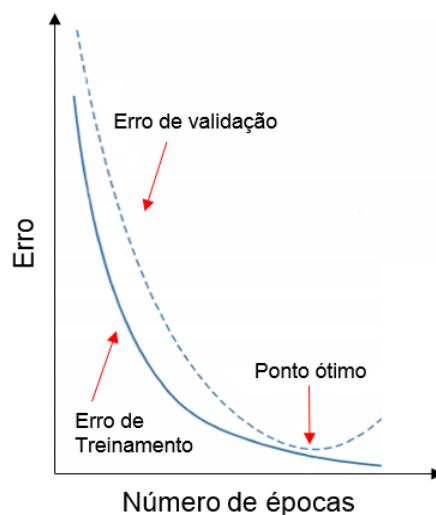
em que  $n_c$  representa as condições a serem separadas.

Tratando-se sobre validação e análise de topologias, é necessário frisar que durante o treinamento, o conjunto dos dados apresentados são separados em dois grupos principais. O primeiro deles é utilizado para o ajustar os pesos sinápticos e os potenciais de ação (chamado de conjunto de treinamento). O segundo é chamado de conjunto de validação e é composto por amostras que são apresentadas aos pesos e limiares ajustados para analisar o desempenho da rede e a sua capacidade de generalização (CHOJACZYK *et al.*, 2010).

Para analisar o desempenho de várias topologias de MLPs, a técnica de validação cruzada é uma das mais utilizadas. Essa técnica avalia a aptidão de cada rede aplicando o conjunto de validação. Quanto a apresentação das amostras durante a validação, há alguns métodos como: a amostragem aleatória, por repartições (em que se reparte o conjunto de dados para serem validados) e a por unidade (caso especial de repartições usando apenas uma amostra de cada vez) (SILVA; SPATTI; FLAUZINO, 2010).

Sabe-se que o erro de treinamento é ligeiramente menor que o erro de validação de uma MLP, conforme apresentado na Figura 20. Tal é a importância do ponto de parada do treinamento com o erro de validação porque com as duas informações consegue-se encontrar o ponto ótimo de funcionamento da RNA. Se o

erro de treinamento for cada vez menor, é muito provável que a rede perca a capacidade de generalização e que se aumenta ainda mais o erro de validação (SILVA; SPATTI; FLAUZINO, 2010).



**Figura 20 – Erros de validação e de treinamento em relação ao número de treinamentos.**  
**Fonte: Silva, Spatti e Flauzino (2010), adaptado.**

## 2.7 CONCLUSÃO DO CAPÍTULO

Ao longo deste capítulo, foram apresentados, em forma de revisão bibliográfica, os conceitos relacionados ao desenvolvimento da *armband* e do sistema de classificação. Estes conceitos, que abrangem a fisiologia do processo celular da eletromiografia, a características de seus sistemas de condicionamento e processamento, fusão de sensores e Redes Neurais Artificiais baseiam a construção da aplicação apresentada.

Os próximos capítulos aprofundam a metodologia empregada na pesquisa e as particularidades do sistema desenvolvido.

### 3 METODOLOGIA

Após a apresentação da proposta deste trabalho e dos principais conceitos teóricos presentes na literatura, pôde-se desenvolver uma metodologia a fim de conseguir atingir os objetivos anteriormente citados.

O primeiro passo consiste da construção de um sistema em formato de bracelete em que os eletrodos estejam inseridos. Uma das premissas deste estudo é utilizar uma distância igual entre canais (canais equidistantes) além da mesma distância entre eletrodos. Esse conceito permite que a distribuição dos eletrodos consiga abranger quase a totalidade do membro em que está inserido. O contrário também pode ser feito (a concentração de eletrodos apenas em áreas de maior atividade muscular), porém, o bracelete perderia sua visão generalista e a percepção do efeito da dispersão do sinal de sEMG por entre as fibras musculares e a pele, o que pode auxiliar no processo de classificação. Utilizando tal medida, há a possibilidade da atuação em outros grupos musculares com a mesma premissa de *armband*.

Com a construção realizada, o próximo passo é o desenvolvimento de circuitos que adquiram os sinais de sEMG. Seus critérios de projeto baseiam-se nas características apresentadas nas seções anteriores. Além de seu projeto, estes circuitos devem ter sua resposta analisada por meio de *softwares* de simulação e testes com equipamentos apropriados. Sua montagem inicial foi realizada em matrizes de contato (*protoboard*) e para então, serem desenvolvidas placas de circuito a fim de garantir melhores respostas ao sistema.

O procedimento seguinte é a inserção do sensor inercial ao sistema, sendo que nessa aplicação escolheu-se um giroscópio. Para essa aplicação, utilizou-se o giroscópio pela sua facilidade de indicar o movimento sem a necessidade de realizar processamentos. Isso porque no uso de acelerômetros, é preciso realizar operações a fim de retirar a influência da aceleração da gravidade nos eixos. Por outro lado, o giroscópio consegue medir o sentido do movimento pela velocidade angular, e quando cessa o movimento, este retorna ao valor de zero. Pela disponibilidade, foi escolhido um modelo MEMS. Com os dados destes, a informação pode ser cruzada com dados de sEMG para as análises pretendidas, especialmente pela informação de quando (no tempo) houve o começo dos movimentos do membro superior.

Segue-se, então, o estágio do desenvolvimento do módulo de aquisição. A função dessa etapa é, por meio de *software*, capturar os dados de sEMG e do giroscópio de forma síncrona e salvá-los em um banco de dados para serem usados nas etapas de processamento. Optou-se pelo uso do programa LabVIEW™ pela sua facilidade de aquisição e processamento dos dados de forma *online*. Para que os dados possam seguir um mesmo padrão, há a necessidade de um protocolo. Essa padronização auxilia as etapas posteriores a dividirem as classes e a contornar a natureza estocástica do sinal. Foi idealizada uma metodologia sob a forma de protocolo para a captura dos dados, estando os circuitos e sistemas de eletromiografia aprovados pelo Comitê de Ética em Pesquisa envolvendo Seres Humanos da UTFPR (CAAE 30162814.5.0000.5547).

O protocolo desenvolvido que também baseou a construção do *software* de aquisição foi:

- Passo 1. Inserir a *armband* e o giroscópio no braço e no punho, respectivamente, através da colocação dos eletrodos e no bracelete (inserindo o primeiro canal na região do ventre muscular do bíceps braquial);
- Passo 2. Energizar a *armband* pelas baterias e o giroscópio, a qual está conectada ao computador sem conexão com a rede elétrica;
- Passo 3. Perguntar e analisar o conforto do indivíduo, se o sistema não está apertado e/ou causando irritação;
- Passo 4. Inicializar o sistema de aquisição de dados, pedindo para o indivíduo ficar em alerta com um indicador de movimento, o qual orienta a pessoa na condução do movimento nos momentos em que ela deve flexionar ou estender o antebraço no plano Y;
- Passo 5. Orientar a pessoa que flexione e estenda o braço em um tempo estimado de 3 segundos, pedindo, primeiramente, para que contraia os músculos correspondentes ao movimento (bíceps durante a flexão e tríceps na extensão);
- Passo 6. Repetir 10 vezes essa sequência de movimentos (totalizando 20 movimentos ao total) e aguardar 1 minuto para a próxima seção, salvando os dados no computador;
- Passo 7. Fazer o total de 5 seções com a *armband*, sendo metade delas orientando a pessoa a movimento o braço normalmente, sem aplicação de grande esforço muscular;

Passo 8. Após terminadas as seções, desligar os sistemas e os retirar do indivíduo.

Para a montagem de um banco de dados, escolheu-se pessoas saudáveis, sem a presença de doenças musculares ou miopatias no membro superior para a captura dos dados. Ao todo, foram coletados dados de 7 indivíduos acima de 18 anos, com a média de idades de 26 anos (com desvio padrão de 6,60), composto por 4 indivíduos do sexo masculino e 3 indivíduos do sexo feminino. Para a montagem de um banco de dados, cada indivíduo realiza cerca de 50 movimentos, totalizando 700 movimentos com todos os indivíduos.

O passo subsequente consiste da elaboração de um sistema de tratamento e processamento *offline* dos sinais coletados em *software*. Também optou-se pelo programa LabVIEW™ para o desenvolvimento dessa etapa pela sua facilidade de programação com sistemas de processamento de sinais bem como a forma de apresentação dos seus dados. Com base nos sistemas de processamento de sEMG, o *software* lê os arquivos presentes no banco de dados, segmenta os sinais eletromiográficos e fornece as características extraídas para que o classificador possa ser alimentado com essas informações.

Após o processamento dos dados, o estágio seguinte é o desenvolvimento do classificador em forma de RNA, implementado em *software* MATLAB®. Os dados, recolhidos dos voluntários, são organizados para a entrada na rede, na qual rotinas auxiliam este processo para melhorar a generalização. As redes foram construídas utilizando como sugestão de número de neurônios na camada escondida os critérios de Kolmogorov e Weka, sendo os dados normalizados por meio do método de desvio padrão. Após a programação destas redes, as topologias são avaliadas por meio de validação para analisar a capacidade de aprendizado e classificação da rede ao problema apresentado.

Por fim, com os dados obtidos, a aplicação como um todo é discutida, apresentando suas dificuldades, resultados obtidos e novas perspectivas de trabalho.

## 4 DESENVOLVIMENTO

Como proposta de *armband*, foi desenvolvido um sistema para a medição dos sinais provenientes dos grupos musculares do braço (bíceps braquial, tríceps e regiões entre estes músculos) e detecção dos movimentos de flexão e extensão do antebraço.

Este capítulo apresenta as características tanto físicas da *armband* construída quanto as características do sistemas em *software* para o processamento do sinal. São consideradas as características físicas o arranjo dos eletrodos, seus circuitos de aquisição e condicionamento e a inserção do giroscópio no sistema para a captação da velocidade angular (todas constituindo o *hardware* do sistema). Por outro lado, os sistemas em *software* constituem-se dos responsáveis pela aquisição, processamento e classificação (por Redes Neurais Artificiais) dos sinais obtidos pelo sistema físico.

### 4.1 CONCEPÇÃO FÍSICA

A primeira proposta do sistema está esquematizada na Figura 21. Ao total, foram projetados a construção de oito canais bipolares. Cada canal possui uma distância entre eletrodos de  $\pm 2$  cm, seguindo as recomendações dos estudos de Hermens *et al.* (2000). A distância entre cada canal foi definida pelo tamanho total da *armband*. A princípio, foi realizada uma média com os valores de comprimento do braço dos pesquisadores e definiu-se uma distância fixa entre canais de  $\pm 3,21$  cm, totalizando uma distância de  $\pm 26,5$  cm. Uma folga foi deixada para a melhor fixação do material. Para a colocação dos eletrodos, foram costurados contatos de pressão metálicos em uma tira de Velcro<sup>3</sup>. Estes valores de comprimento foram escolhidos, a priori, pelo perímetro do braço dos pesquisadores, porém, deseja-se deixar estes valores ajustáveis para próximas implementações, sabendo que o material usado não foi elástico o suficiente para entrar em demais indivíduos.


Essa construção apresenta certas vantagens, sendo a primeira delas permitir que haja um espaçamento igual para todos os eletrodos, dada pela padronização da

---

<sup>3</sup> Velcro é a marca de um fixador, consistido em ganchos e laços usado para conectar objetos. É composto por fitas que se aderem, substituindo fechos, botões, fivelas e cordões. Um lado é composto por um pedaço de tecido coberto por pequenos ganchos plásticos, enquanto que o outro lado é coberto por pedaços de voltas plásticas menores.



localização. Isso é perceptível quando os sinais são transmitidos (especialmente), fornecendo o mesmo aspecto mas com formatos reduzidos, oferecendo confiabilidade à natureza do dado obtido. Outra vantagem é a diminuição de artefatos. Geralmente em sistemas dinâmicos, os eletrodos podem desconectar da interface eletrodo-pele. O sistema com velcro permite ajustar o *armband* no antebraço e ainda fazer uma leve pressão entre os eletrodos, os quais também possuem gel eletrólito e adesivos de fixação.



**Figura 21 – Esquemático do primeiro protótipo do conjunto de eletrodos.**  
**Fonte: Autoria própria.**

Os eletrodos utilizados foram de Prata/Cloreto de Prata (Ag-AgCl), típicos para ECG (modelo MSGST-06, marca Solidor), em formato circular com diâmetro de 0,7 cm. Porém, eles foram modificados para serem utilizados na *armband*. A Figura 22a apresenta o resultado da customização, em que as bordas dos eletrodos foram cortadas para se ajustarem no dispositivo. Ao total, manteve-se largura de 1,9 a 2 cm (tamanho aproximado da cobertura do gel eletrólítico, o qual cobre uma circunferência de diâmetro 1,8 cm) com comprimento de 3,1 cm. Não manteve-se o comprimento total do eletrodo (4,3 cm) para poder deixar uma distância aproximada de 1 cm entre o centro do eletrodo com a borda adesiva. Essa medida por adotada pois, como são usados dois eletrodos em cada canal, padroniza-se a distância entre eletrodos de 2 cm. Os contatos de pressão, ou colchetes, são mostrados na Figura 22b, bem como seu encaixe nos eletrodos. Os contatos possuem diâmetros de 1,2 cm e o que garante sua fixação são as hastes do colchete, ajustados manualmente para garantir melhor

contato. A colocação (a) e os contatos de pressão (b) na *armband* são apresentados na Figura 23.




Figura 22 – Dimensão a) dos eletrodos antes e depois do ajuste e b) dos contatos de pressão e sua fixação nos eletrodos.

Fonte: Autoria própria.



Figura 23 – Visão inferior da *armband*, em destaque a) com os eletrodos e b) os contatos de pressão.

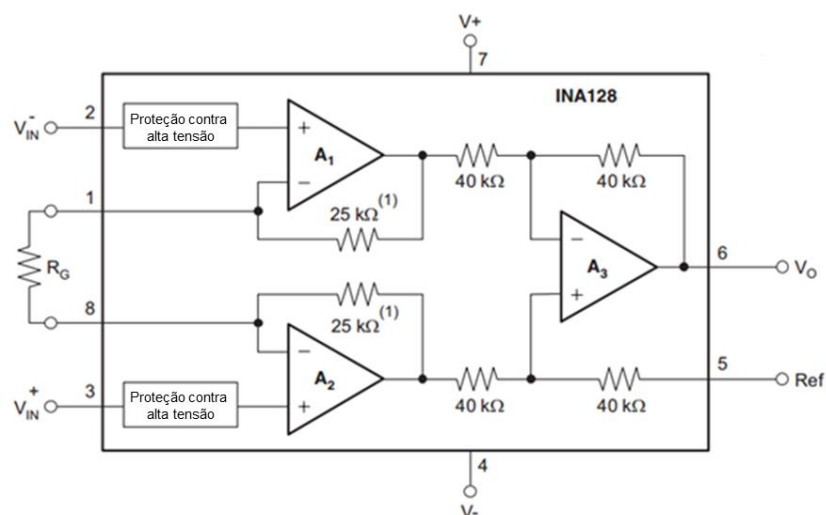
Fonte: Autoria própria.

Sobre o uso destes contatos, é necessário discorrer que seu material é o mesmo para todos os botões. Todos os eletrodos são feitos do mesmo material (latão), logo, todos possuem as mesmas características elétricas. Além dos oito canais (totalizando 16 contatos costurados na *armband*) também foi usado um contato para alocação do eletrodo de referência, posicionado em uma região externa da *armband*.

#### 4.1.1 Amplificador de Instrumentação

Após a captura dos sinais pelos eletrodos, estes passam por um amplificador de instrumentação que realiza a função de pré-amplificador. O amplificador de instrumentação utilizado foi o circuito integrado INA 128P.

Um INA (do inglês, *Instrumentation Amplifier*) é um amplificador de alta precisão, de propósito geral (comumente utilizado em sistemas de aquisição de dados, amplificadores em ponte, amplificadores termoacoplados e instrumentação biomédica) com baixo consumo. No INA 128P, a faixa de ganhos pode variar de 1 até 10000, com alto ganho de largura passante, alta CMRR e alta impedância ( $10^{11} \Omega$ ). Permite alimentações simétricas que variam de 2,25 V até 18 V (TEXAS INSTRUMENTS, 1995). Seu esquemático interno é apresentado na Figura 24.



**Figura 24 – Bloco funcional interno de um INA 128P.**  
**Fonte: Texas Instruments (1995), adaptado**

A equação do ganho do INA128 é dada por (26), seguindo a função de transferência dos amplificadores de instrumentação da equação (9)

$$G = 1 + \frac{50k}{R_G} \quad (26)$$

em que:

G representa o ganho total do amplificador (adimensional); e


$R_G$  representa o resistor de ganho (em  $\Omega$ ).

Para encontrar o valor de  $R_G$ , a equação (27) foi rearranjada na equação (27)

$$R_G = \frac{50k}{G-1} \quad (27)$$

Foi decidido utilizar um valor de ganho de 10, usual em sistemas de pré-amplificação; já que podem ser caracterizados como tais pela proximidade com a área de captação. Com esse valor de ganho, o resistor de ganho calculado seria de 5,556 k $\Omega$ . O valor comercial próximo é 5,6 k $\Omega$   $\pm$ 5%, o qual foi usado no circuito. O ganho real do circuito calculado para essa situação é 9,928, com um erro de 0,72%. Porém, todos os resistores foram medidos e sua resistência estavam em torno de 5,5 k $\Omega$ , variando na segunda casa decimal. Dessa forma, os valores de ganho estão muito próximos do projetado.

Foram construídas, ao todo, quatro placas com amplificadores para serem fixados na *armband*. A Figura 25 apresenta um dos modelos do circuito de amplificação, contendo em cada placa, dois INAs e dois resistores  $R_G$ . Na parte superior, estão os terminais de alimentação e de saída do sinal, enquanto que na parte inferior estão os terminais para a ligação dos cabos aos eletrodos. Há três furos nas extremidades da placa para permitir que a mesma pudesse ser costurada na *armband*.



**Figura 25 – Placa do circuito de amplificação.  
Fonte: Autoria própria.**

#### 4.1.2 Filtro anti-aliasing

A fim de delimitar a banda do sinal de sEMG e de atenuar o efeito de serrilhamento (*aliasing*), foram projetados um filtro *anti-aliasing* para cada canal. Sendo este filtro um passa-baixa, a frequência de corte escolhida foi 500 Hz, baseada nas máximas frequências que podem ser extraídas de um sinal de sEMG.

Sabe-se que a frequência de corte para um filtro passa-baixa de primeira ordem contendo capacitor e resistor é determinada pela equação (28):

$$f_c = \frac{1}{2\pi RC} \quad (28)$$


em que:

$f_c$  é a frequência de corte, em Hz;

$R$  é o valor da resistência do filtro, em  $\Omega$ ; e

$C$  é o valor da capacitância do filtro, em F.

Para fins de projeto, inicia-se estipulando um valor de capacitância comercial. Para esse caso, decidiu-se usar um capacitor de 470 nF. Substituindo este valor e o valor da frequência desejada na equação (28), encontra-se o valor para a resistência  $R$  de 677,25  $\Omega$ . O valor comercial mais próximo é 680  $\Omega$ . Com estes valores sendo substituídos na equação (28), a frequência de corte calculada  $f_c$  é de 497,98 Hz, representando um erro de 0,404 %. Para essa construção, foram usados capacitores e resistores em formato de montagem superficial (ou SMD, *Surface-Mount Technology*). A Figura 26 apresenta o circuito montado para alocação dos filtros *anti-aliasing*.




**Figura 26 –Filtros *anti-aliasing* propostos, sendo a) seu esquemático e valores comerciais e b) na placa.**

**Fonte: Autoria própria.**

#### 4.1.3 Sistema de aquisição

Por fim, o sistema final da *armband* com os eletrodos e os circuitos pode ser visto na Figura 27. Percebe-se aqui a presença do eletrodo de referência, que nas aplicações que seguem, é inserido na região do cotovelo. A alimentação dos circuitos é feita por duas baterias de 9 V de forma simétrica, de tal forma que a alimentação do circuito está isolada da rede elétrica de alimentação. A saída dos circuitos de

condicionamento é ligada a uma placa de aquisição de dados (NIDAQ USB 6212). Essa placa é responsável por fazer a aquisição dos sinais de sEMG para serem processados via *software* em um computador. O *software* questão foi o LabVIEW™ que possui conectividade direta com a placa de aquisição de dados. Para adquirir estes dados, escolheu-se um *notebook* operando a bateria. Além da proteção do usuário, atenua-se também os ruídos com frequência de 60 Hz. Ressalta-se se que a utilização dessa placa ocorre de forma temporária, apenas para adquirir os dados e processá-los, pois em uma aplicação final, sistemas de comunicação sem fio seriam usados para o envio dos dados.



**Figura 27 – Vista superior do sistema de *armband*, placa de aquisição e circuitos de condicionamento.**  
**Fonte: Autoria própria.**

O NIDAQ 6212 é um sistema de aquisição de dados dedicado a aplicações móveis, com conectividade *plug-and-play* e alimentação por meio de barramento e interface USB. Dentre as suas características mais relevantes para esse trabalho, estão os seus 16 canais analógicos. Estes canais podem ser ligados separadamente com um só referencial (operação *single ended*) ou de forma diferencial (com 8 canais nessa configuração). A taxa de amostragem total do sistema é de 400 kS/s, com uma resolução de 16 bits, faixa dinâmica (range de conversão) podendo variar de  $\pm 0,2$  a

$\pm 10$  V, alta impedância de entrada ( $10\text{ G}\Omega$ ) e CMRR na faixa de 100 dB (NATIONALS INSTRUMENTS, 2014).

Para a aplicação, o sistema foi configurado para atuar em operação *single ended* com frequência de amostragem de 2 kHz. Essa frequência foi escolhida para amostrar o sinal de sEMG devido a sua banda máxima de frequências (500 Hz). Após serem adquiridos pela placa, foram encaminhados para um *software* criado em ambiente LabVIEW™. Porém, antes da explanação desse *software*, apresenta-se o sensor inercial utilizado para a captação do movimento.

#### 4.1.4 Giroscópio (L3G4200D)

O sistema MEMS L3G4200D foi o giroscópio utilizado, composto por um sistema triaxial digital. Entre as características desse sistema, destacam-se a seleção de escalas, resolução de 16 bits, programação de filtros passa-alta e passa-baixa digitais, baixo consumo e alta sensibilidade. É aplicado, principalmente, como sensor em sistemas de realidade virtual e jogos, em sistemas de controle de movimento em interfaces homem-máquinas, em eletrodomésticos, em aplicações robóticas e sistemas de navegação (ST MICROELECTRONICS, 2010).

No sistema, o L3G4200D foi programado por meio de comunicação I<sup>2</sup>C, com a escala de 2000 dps (do inglês, *degrees-per-second*, graus por segundo). De acordo com o fabricante, o valor bruto (*raw*) deve ser multiplicado pelo valor adimensional de 0,07 para obter o valor em dps. Foram habilitados a captura dos três eixos, sendo programado um filtro passa-alta com frequência de corte de 0,5 Hz e um passa-baixa com frequência de corte de 25 Hz. Esta faixa foi utilizada a fim de atenuar ruídos na faixa DC (abaixo de 0,5 Hz) e limitar a banda do sinal.

Para ler os dados do giroscópio, foi utilizado um microcontrolador ATmega 2560 (Atmel), disponível em uma plataforma Arduino Mega. A Figura 28 apresenta a ligação física. O Arduino Mega comunica-se com o giroscópio por meio da comunicação I<sup>2</sup>C e foi programado para enviar os dados por meio de comunicação serial para o computador, com uma taxa de transmissão de 9600 bauds.







Figura 28 – Ligação com o Arduino Mega com o giroscópio.  
Fonte: Autoria própria.

Para o acompanhamento dos movimentos de flexão e extensão do braço, o giroscópio foi acomodado em um bracelete localizado na região do pulso. O sensor foi posicionado de tal forma que o eixo Y fosse responsável por indicar esses movimentos; em outras palavras, o único a ter maior representatividade das velocidades angulares do braço. Essa posição, juntamente com a da *armband*, é apresentada na **Erro! Fonte de referência não encontrada.**, com as indicações dos movimentos e dos eixos do sensor inercial. Nessa aplicação, ao ser realizada a flexão, o giroscópio apresenta valores positivos de velocidade, enquanto que na extensão, valores negativos. Quando o braço está em situação de repouso, ou seja, parado em qualquer posição, o sensor apresenta resposta próxima ao valor nulo (zero).

Outro ponto de análise é a taxa de amostragem dos dados do giroscópio. Em sistemas de leitura de movimentos, recomenda-se usar uma frequência entre 10 a 100 Hz (LABRADOR; YEJAS, 2013). Foi escolhido, então, amostrar os dados utilizando uma frequência de 50 Hz. O programa de leitura foi otimizado para realizar a atualização destes dados com essa frequência fixa (no período de tempo de 20 ms), bem como para serem sincronizados com os dados de sEMG.





**Figura 29 – Sistema *armband* e giroscópio com indicação de seus eixos e direção dos movimentos de flexão e extensão.**  
**Fonte: Autoria própria.**

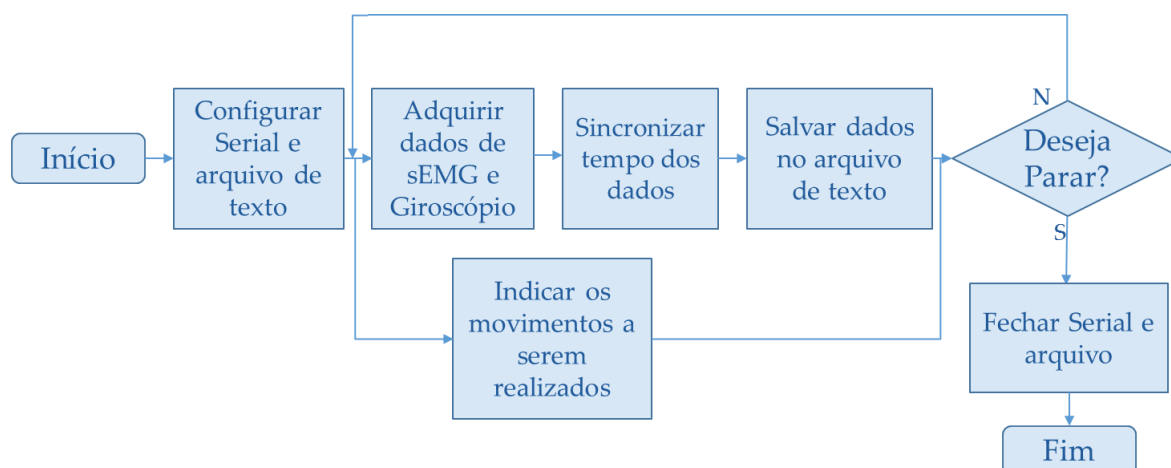
A mensagem enviada pela interface serial foi organizada endereçando cada valor de velocidade angular após a indicação do seu eixo. Por exemplo, a mensagem “X10Y100Z40”, significa que o valor 10 para o eixo X, 100 para o eixo Y e 40 para o eixo Z, respectivamente. Usando essa correspondência, pode-se ter a certeza de qual dado pertence a determinado eixo.

## 4.2 SOFTWARE DE AQUISIÇÃO

Com a montagem do arranjo dos eletrodos, dos circuitos de captação de sEMG e da inserção do giroscópio com o seu microcontrolador, pode-se desenvolver o sistema para a captação dos dados de forma síncrona.

A **Erro! Fonte de referência não encontrada.** apresenta o fluxograma do programa responsável pela aquisição dos dados de sEMG e do giroscópio. Essa representação é uma simplificação do código desenvolvido no Diagrama de Blocos do LabVIEW™, sendo este detalhado no Apêndice A.

Ao iniciar o programa, são configurados os parâmetros para a leitura dos dados provenientes da comunicação serial com o Arduino e o nome do arquivo de texto. Foi utilizada uma taxa de transmissão (*baudrate*) de 9600 bauds, taxa suficiente para a frequência desejada de 50 Hz para o giroscópio. Após essa etapa, o programa entra em seu *loop* principal.



**Figura 30 – Fluxograma do diagrama de blocos do VI de aquisição em LabVIEW™**  
**Fonte: Autoria própria.**

A primeira ação dentro do *loop* é a aquisição dos sinais tanto de sEMG quanto do giroscópio. A placa de aquisição NIDAQ 6212 possui conectividade direta com o LabVIEW™, logo, os 8 canais de sEMG foram configurados para coletarem sinais com uma taxa de amostragem de 2 kHz, com um *buffer* de 40 dados por canal. Isso gera um atraso entre cada atualização dos dados de 20 ms (ou a cada 50 Hz). Por sua vez, os dados do giroscópio são simultaneamente adquiridos pela comunicação serial (configurada anteriormente).

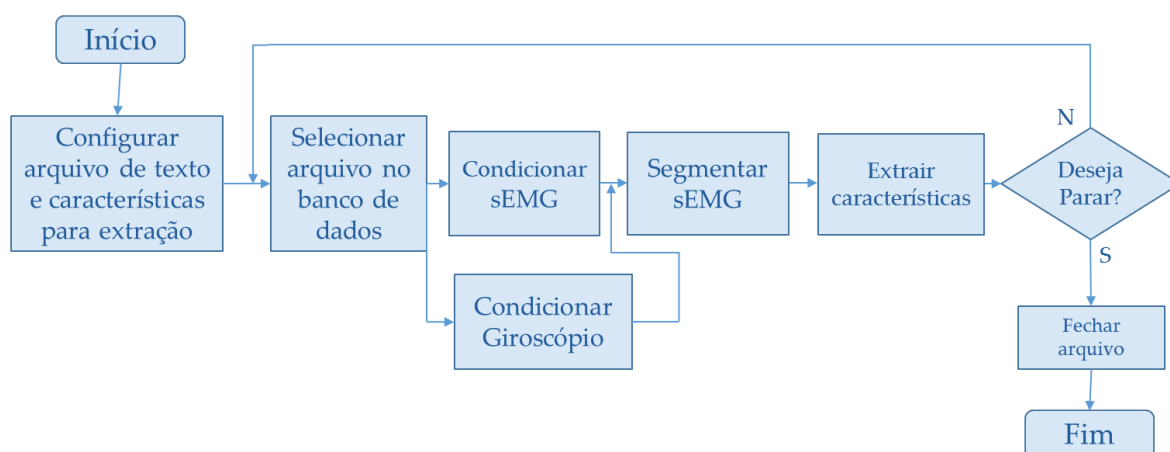
Ao encher o *buffer* (40 dados de cada canal de sEMG mais 1 dado do giroscópio), é sincronizado o tempo de execução do *loop*. Essa sincronização ocorre para garantir a exatidão de tempo entre cada grupo de amostras. Os dados então são agrupados para serem salvos em um arquivo de texto. Paralelamente, um indicador visual apresenta ao usuário qual movimento deve ser realizado (flexão ou extensão).

O *loop* continua executando o mesmo conjunto de operações (aquisição, sincronização, gravação dos dados e indicação de movimento) até o usuário desejar para a sua execução. Quando o usuário o encerra, a comunicação serial é finalizada com o fechamento da porta de comunicação junto com o arquivo em que os dados estão sendo salvos.

#### 4.3 SISTEMA DE CONDICIONAMENTO E PROCESSAMENTO

Após os dados serem adquiridos, iniciou-se o seu processamento ainda com o *software* LabVIEW™. Essa etapa tem como finalidade abrir os arquivos salvos

anteriormente no banco de dados, tratar os dados ali presentes, segmentá-los, extrair as suas características e indicar se correspondem aos movimentos de flexão e extensão. Por fim, os dados são salvos em um arquivo para serem enviados ao classificador. O fluxograma das operações desse VI é apresentado na **Erro! Fonte de referência não encontrada.** e seu diagrama de blocos expandido é apresentado no Apêndice B.



**Figura 31 – Fluxograma do VI de condicionamento e processamento no Diagrama de Blocos em LabVIEW™.**  
**Fonte: Autoria própria.**

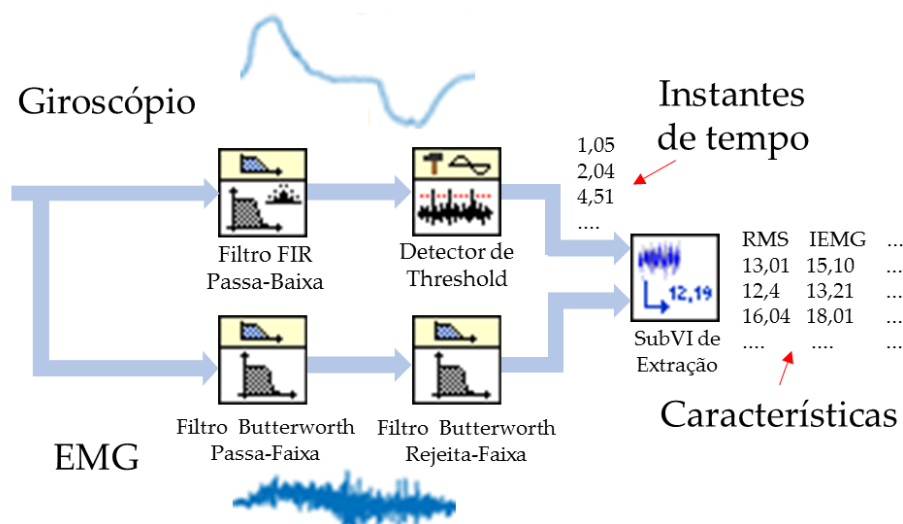
O início do programa ocorre com as configurações de salvamento do arquivo resultante e com a escolha das características a serem extraídas do sinal. Após essas definições, o sistema parte para o seu *loop* principal.

Os dados coletados na etapa anterior são selecionados, um arquivo a cada operação. O programa abre-os e os separa, para então, serem condicionados. Como o LabVIEW™ utiliza processamento paralelo, estes dados podem ser condicionados ao mesmo tempo. O sinal de sEMG passa por um conjunto de filtros: passa-banda (com frequência de corte passa-baixa de 450 Hz e passa-alta de 10 Hz) e *notch* (rejeita-faixa com frequências entre 59 a 61 Hz). Ambos os filtros possuem topologia IIR, de segunda ordem com aproximação Butterworth. O filtro passa-banda delimita a faixa de frequência do sinal a ser processado e o filtro rejeita-faixa atenua a frequência de 60 Hz da rede elétrica de alimentação.

Por outro lado, o sinal do giroscópio passa por um filtro passa-baixa com frequência de corte de 20 Hz com topologia FIR. Escolheu-se utilizar este filtro com janela Hamming com ordem 101. Dessa forma, pode-se calcular qual é o atraso de

tempo da ação do filtro, necessário para estimar o tempo em que giroscópio foi ativado. O sinal suavizado pelo filtro passa por um detector de limiar, que informa em quais instantes de tempo o valor ultrapassou o valor de  $10^0$ /segundo. Dessa forma, detecta-se as passagens positivas (que representam as flexões) e negativas (que representam as extensões).

Com os instantes de tempo pela análise de limiar do giroscópio, pode extrair as características do sinal de sEMG. Esse processo é apresentado resumidamente na Figura 32. Anteriormente a extração, ocorre a segmentação dos dados. Definiu-se um período de tempo de 300 ms, baseado no estudo de Englehart e Hudgins (2003), os quais compõe de um total de 600 amostras por canal. Por fim, as características são extraídas e apresentadas em formato numérico. Foram calculadas a MAV, a integral do sinal, a variância dos seus dados e o seu valor RMS, sendo inseridas se o movimento pertence a flexão ou extensão. O usuário pode fazer a opção de continuar executando as ações de condicionamento e processamento em para outro arquivo ou então encerrar o processo. Ao encerrar, é salvo o arquivo com as características escolhidas pelo usuário.



**Figura 32 – Esquemático de operações para extração de características.**  
Fonte: Autoria própria.

#### 4.4 CLASSIFICAÇÃO POR REDES NEURAIS (MLP)

O último estágio do sistema de processamento trata-se da implementação do classificador RNA Perceptron de Múltiplas Camadas (MLP). O código da rede está disponível no Apêndice C, sendo desenvolvido por meio de *scripts* no *software*

MATLAB®. O sistema foi testado com os dados referentes às 7 pessoas, com as 4 características (MAV, RMS, Variância e IEMG). Os dados, antes de entrarem para a rede, foram normalizados utilizando a regra do desvio padrão, dada pela equação (29):

$$X_{NORM} = \frac{X_N - \bar{X}}{\sigma} \quad (29)$$

em que:

$X_{NORM}$  é a amostra normalizada;

$X_N$  é a amostra a ser normalizada;

$\bar{X}$  é a média de todas as amostras do sinal; e

$\sigma$  é o desvio padrão de todas as amostras.

A fim de auxiliar o processo de análise da rede e da classificação dos dados, todos as amostras inseridas são aleatoriamente misturadas entre padrões de flexão e extensão; já que na saída do sistema de classificação, as amostras com as mesmas respostas tendem a ficar muito próximas. Sendo primeiramente executado o *script* “Organizar\_Dados” (Apêndice C), é também escolhida a quantidade de amostras para o treinamento e para o teste da rede. Separou-se 560 amostras (80%) para treinamento e 140 amostras (20%) para etapa de teste/validação (sendo 70 extensões e 70 flexões).

Estando as saídas e as entradas preparadas, foi desenvolvida a MLP, utilizando os passos e as equações descritas anteriormente. Escolheu-se desenvolver uma MLP com uma camada de entrada, uma camada de saída e uma camada escondida. Os principais aspectos topológicos e da arquitetura da implementação estão descritos na Tabela 2, os quais foram implementados utilizando as topologias com o número de neurônios na camada escondida pelos critérios de Kolmogorov e Weka.

A validação da rede foi feita treinando-a e testando-a por um número de vezes definido de forma empírica (30 treinamentos), pelo método k-amostras, sendo que k é o valor definido de amostras para teste (100 amostras), apresentados arbitrariamente. Para o teste da topologia adequada para essa aplicação, o mesmo conjunto de dados foram apresentados tanto para a que possuía os critérios de Kolmogorov e Weka.

Tabela 2 - Principais características da MLP construída com MAV

Parâmetro	Valor	Considerações
$n_0$ = número de neurônios da camada de entrada	$n_0=32$	A princípio, a camada de entrada possui a quantidade de características escolhidas pela quantidade de canais.
$n_1$ = número de Neurônios da camada escondida	$n_1=65$ $n_1=17$	Utilizando os critérios de <i>Kolmogorov</i> e <i>Weka</i> como ponto de partida, definiu-se a quantidade de neurônios na camada escondida.
$n_2$ = número de neurônios da camada de saída	$n_2=2$	Como é comum em sistemas de classificação, o número da camada de saída é o mesmo da quantidade de classes.
Função de ativação da camada escondida	Tangente hiperbólica	É uma função diferenciável que pode assumir valores negativos quanto positivos entre -1 e 1, usados para estimar o primeiro conjunto de pesos.
Função de ativação da camada de saída	Logística	É uma função diferenciável que apenas assume valores positivos entre 0 e 1, pois o estado das saídas apenas pode assumir valores de 0 ou 1.
$b_1$ = inclinação da função tangente hiperbólica	$b_1=0,5$	A inclinação da função tangente hiperbólica permite selecionar um valor que equilibre o uso da função matemática e não sature os neurônios, inviabilizando seu uso.
$b_2$ = inclinação da função logística	$b_2=0,5$	Idem ao anterior, mas dessa vez para a função logística
$W_1$ =primeiro conjunto de pesos	$W_1$ = Matriz ( $n_1 \times 33$ )	Pesos sinápticos entre a camada de entrada e a escondida, com disposição $n_1$ linhas por 32 colunas; gerada com números aleatórios negativos e positivos.
$W_2$ =primeiro conjunto de pesos	$W_2$ = Matriz ( $2 \times n_1+1$ )	Pesos sinápticos entre a camada escondida e a de saída, com disposição 2 linhas por $n_1+1$ colunas; gerada com números aleatórios positivos.
$n$ = taxa de aprendizagem	$n=0,001$	Valor baixo para a correção dos pesos sinápticos a cada época de treinamento.
$e$ = precisão do erro	$e=5\mu$	É a precisão do erro médio quadrático, a qual é usada como um critério de parada do treinamento.
época	Parada com 10000	Contador da quantidade de vezes que o sistema apresenta todas as amostras durante o treinamento. Como critério de parada do treinamento, definiu-se um valor de 10000 épocas.

Fonte: Autoria própria.

## 4.5 CONCLUSÃO DE CAPÍTULO

Neste capítulo foram apresentados todas as etapas de desenvolvimento do sistema *armband*. Percebe-se que ele funciona a partir da complementação de técnicas, tanto desenvolvidas em *hardware* como em *software*. Além disso, foram fornecidas informações detalhadas sobre a construção, para que também possa ser replicada. A seguir são apresentados os resultados de cada etapa desenvolvida.

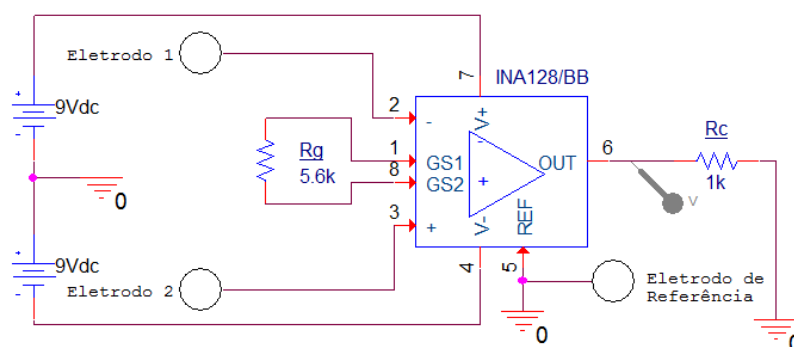
## 5 RESULTADOS

Nesta seção são apresentados os resultados referentes aos testes dos circuitos de condicionamento dos sinais, dos *softwares* e interfaces desenvolvidas, bem como as taxas de acerto do sistema de classificação.

### 5.1 RESULTADOS OBTIDOS DO SISTEMA FÍSICO

#### 5.1.1 Amplificação

Com o valor calculado para o resistor de ganho (secção 4.1.1), o circuito foi simulado utilizando o *software* Orcad/PSPICE®, conforme é apresentado na Figura 33. A resposta em amplitude, verificando o ganho na saída, foi analisada nessa etapa, fixando-se valor de frequência dentro da faixa do sinal de sEMG (100 Hz) e variando-se a sua amplitude (entre 20 e 150 mV, com intervalos de 5 mV). Essa faixa foi escolhida devido a sua proximidade com os valores captados do sinal de sEMG.



**Figura 33 – Circuito de simulação com o INA128 no *software* Orcad/PSPICE**  
**Fonte: Autoria própria**

Como demonstrado matematicamente por meio da equação (26), com o resistor comercial o ganho do sistema obtido foi de 9,928. Utilizando a equação (30), pode-se convertê-lo para a escala logarítmica (em dB).

$$A_{dB} = 20 \text{Log}_{10} \left( \frac{V_{OUT}}{V_{IN}} \right) \quad (30)$$

Em que:

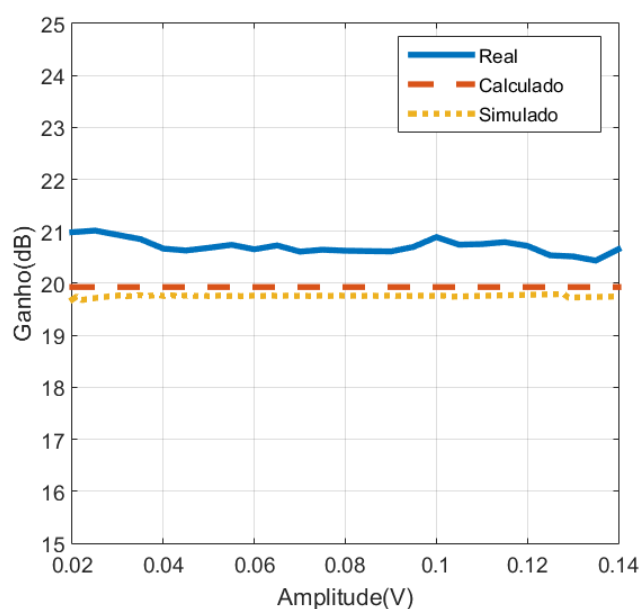
$A_{DB}$  é a relação de ganho em dB (adimensional) ;

$V_{OUT}$  é a tensão de saída (em V); e

$V_{IN}$  é a tensão de entrada (em V).

Dessa forma, o valor teórico calculado de ganho de 19,9 dB (equivalente ao valor adimensional 9,928) é utilizado para comparação dos resultados simulado e prático (real).

O circuito experimental foi analisado em uma matriz de contatos (*protoboard*) com os mesmos parâmetros da simulação, utilizando um gerador de sinal e um osciloscópio. Os valores obtidos experimentalmente, juntamente com os resultados teóricos calculado e simulado são apresentados na Figura 34.



**Figura 34 – Resposta do ganho do circuito de amplificação utilizando o INA 128, sendo apresentados seus valores calculados, simulados e reais.**

**Fonte: Autoria própria.**


Percebe-se pela Figura 34 que os valores reais ficaram ligeiramente acima, tanto dos valores comerciais quanto dos valores calculados, o qual ocorre pela tolerância dos componentes comerciais utilizados (no caso, resistor e amplificador).

### 5.1.2 Filtro *anti-aliasing*

O circuito do filtro *anti-aliasing*, por sua vez, foi simulado também utilizando o software Orcad/PSPICE®, e o seu circuito utilizado na simulação está apresentado na Figura 35. Para tal, foi calculada a resposta em frequência do sinal, variando de 1 Hz




até 10 kHz, com 100 pontos equidistantes a cada década. O valor em dB foi calculado utilizando a equação (30).



**Figura 35 – Esquemático de simulação do circuito do filtro *anti-aliasing*.**  
**Fonte: Autoria própria.**

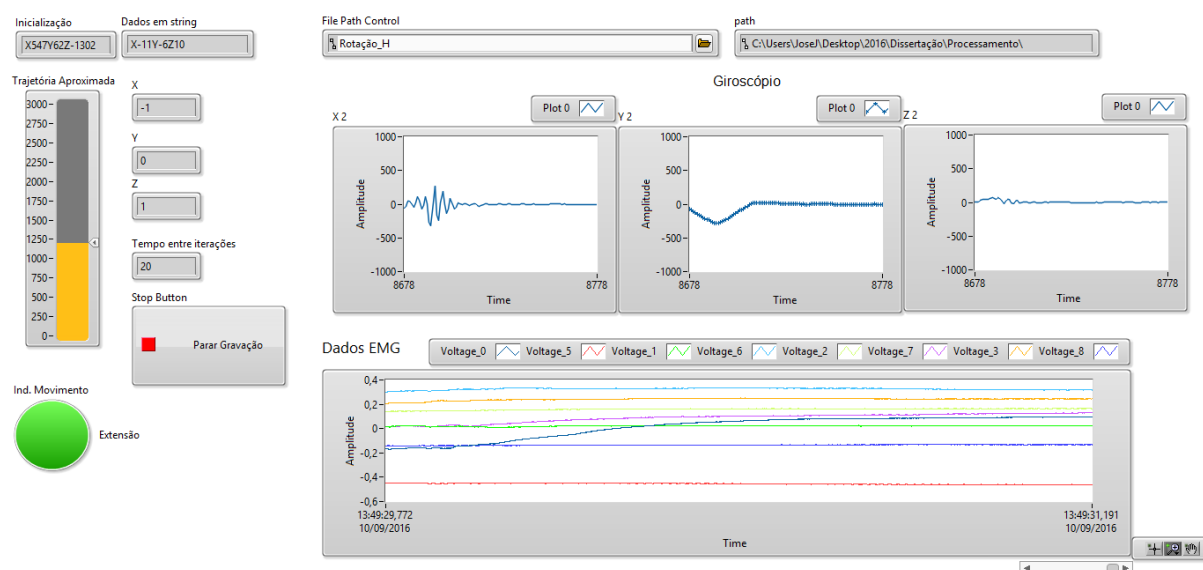
Este filtro também foi experimentalmente testado, variando a frequência entre 1 Hz até 10Hz, com 10 pontos por década (o suficiente para analisar o comportamento do passa-baixa). Os valores simulados e reais estão apresentados na Figura 36. Percebe-se que o circuito real se comportou tal como o esperado pela simulação, com os valores quase sobrepostos.



**Figura 36 – Resposta em frequência da magnitude do filtro *anti-aliasing*, contendo os valores simulados e reais.**  
**Fonte: Autoria própria**

## 5.2 RESULTADOS OBTIDOS COM O SISTEMA DE AQUISIÇÃO

Terminados os testes dos circuitos de condicionamento, verificou-se os *softwares* de aquisição. O Painel Frontal dessa aplicação está apresentado na **Erro! fonte de referência não encontrada.** durante uma captura dos sinais. As configurações e as indicações foram agrupadas no canto esquerdo e superior, enquanto que os sinais são apresentados em gráficos na região central e inferior.

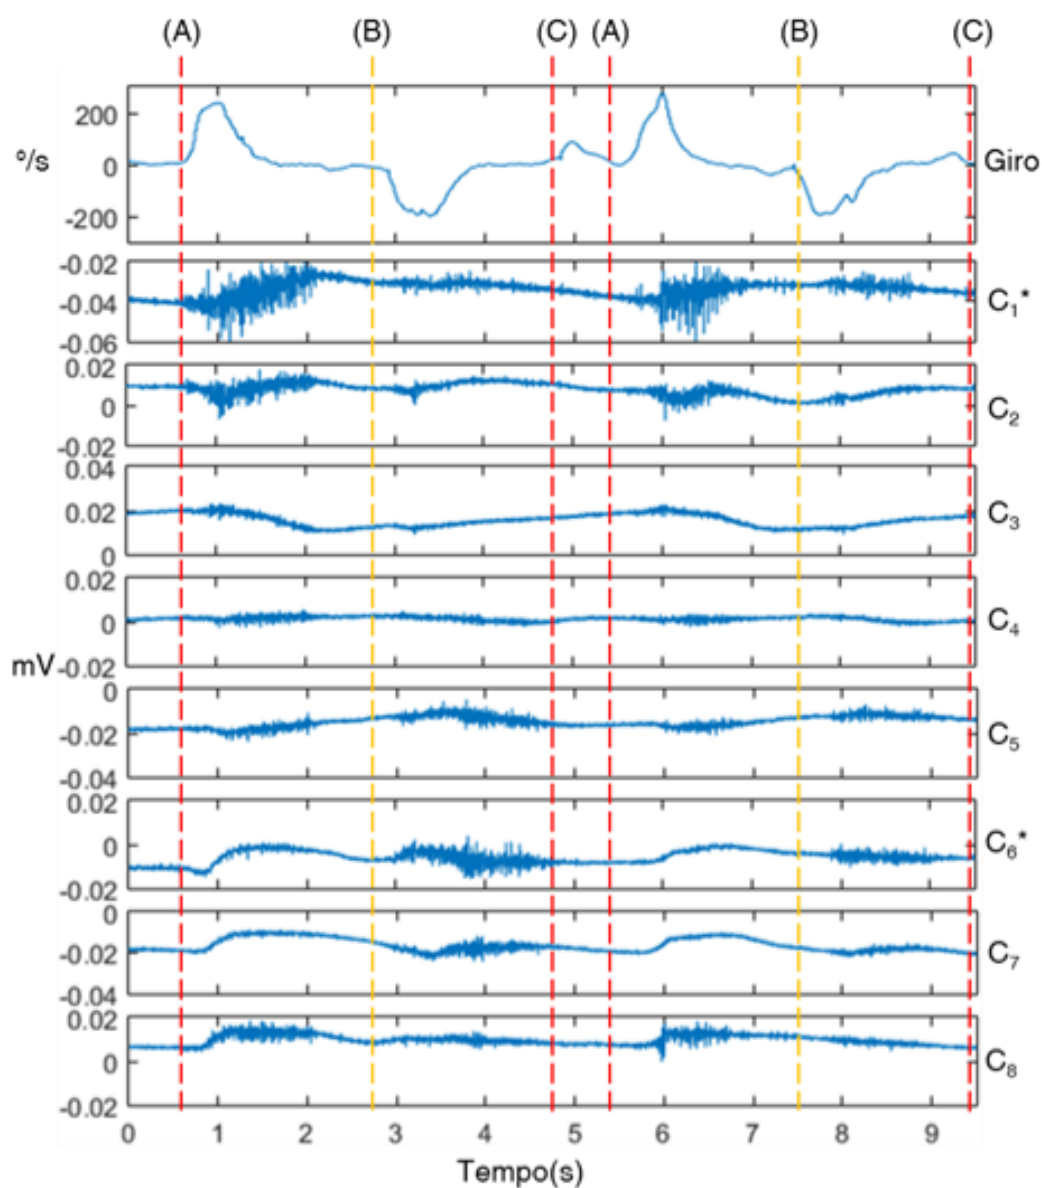


**Figura 37 – Painel frontal do sistema de aquisição de sinais.**  
**Fonte: Autoria própria.**

Após os processos anteriormente descritos, os dados coletados experimentalmente são apresentados na Figura 38. Nesse exemplo, foi selecionado um trecho de um sistema de aquisição. A ação dos movimentos está marcada pelas indicações (A), (B) e (C), representando o início da flexão, o início da extensão e o retorno do braço a posição de repouso, respectivamente. Durante a flexão, nota-se que os canais  $C_1$ ,  $C_2$  e  $C_8$  são os mais ativos, enquanto que na extensão, são os canais  $C_4$ ,  $C_5$  e  $C_6$ . Entretanto, pela amplitude do sinal, nota-se que o canal  $C_1$  está localizado próximo a região central do bíceps braquial e o canal  $C_7$ , do tríceps. Também pode-se perceber a distribuição espacial nos canais adjacentes sujeitos a distribuição espaço-temporal nas fibras musculares.

Como não foi implementada nenhuma etapa de filtragem passa-alta (para não inserir atrasos no sinal em *hardware*), há a presença de ruídos pelos artefatos de movimento, o *offset* (deslocamento) do sinal. A princípio, essa primeira análise não

ficou comprometida. Com a natureza destes dados, pode-se seguir adiante no projeto do sistema de processamento.



**Figura 38 – Dados adquiridos do giroscópio (Giro, em  $^{\circ}/s$ ) e dos oito canais de sEMG  $C_1$  a  $C_8$  (em mV), com a identificação dos movimentos: (A), início da flexão; (B), início da extensão; e (C), final do movimento.**

**Fonte: Autoria própria**

### 5.3 RESULTADOS OBTIDOS COM O SISTEMA DE TRATAMENTO E EXTRAÇÃO DE CARACTERÍSTICAS

A Figura 39 ilustra o Painel de Controle da aplicação contendo um exemplo de dado processado, pelas etapas de tratamento de extração de características. No canto esquerdo, é possível ver os sinais de sEMG e do giroscópio. Percebe-se na parte superior, o sinal de sEMG bruto, sem nenhum processamento; enquanto que na

parte inferior, estão os dados já tratados (etapas de filtragem). Pelo sinal do giroscópio, percebe-se que são três flexões e três extensões. À direita, estão as configurações do programa, como diretórios dos arquivos a serem abertos e salvos, características a serem extraídas, botões para o fluxo de operação do programa, quantidade de dados processados e quantidade de amostras ao total.



**Figura 39 – Painel de monitoramento da rotina de segmentação e extração de características do banco de dados.**  
Fonte: Autoria própria.

O formato de como os sinais são obtidos após o sistema de extração de características é apresentado na Tabela 3. Nela, estão presentes seis amostras para cada característica (MAV, RMS, Variância e IEMG) dos canais  $C_1$  e  $C_2$ . Apenas para exemplificar o formato dos dados, não foram apresentados valores para todos os oito canais. No arquivo, também são apresentadas as saídas S1 e S2, as quais representam se a amostra representa o movimento de flexão ou extensão, respectivamente.

**Tabela 3 – Exemplo de Características Extraídas, exemplificando em seis amostras os valores de MAV, RMS, Variância e IEMG dos Canais C<sub>1</sub> e C<sub>2</sub>.**


Amostra	Canal C <sub>1</sub>				Canal C <sub>2</sub>				Saídas	
	MAV	RMS	Variância	IEMG	MAV	RMS	Variância	IEMG	S1	S2
1	6,78E-04	0,41	7,70E-07	8,74E-04	8,97E-04	0,54	1,36E-06	1,17E-03	1	0
2	5,81E-04	0,35	5,60E-07	7,49E-04	7,77E-04	0,47	9,70E-07	9,83E-04	1	0
3	6,55E-04	0,39	7,00E-07	8,37E-04	8,29E-04	0,50	1,35E-06	1,16E-03	1	0
4	3,87E-04	0,23	2,50E-07	4,95E-04	4,46E-04	0,27	3,50E-07	5,93E-04	0	1
5	4,22E-04	0,25	3,20E-07	5,66E-04	5,72E-04	0,34	6,40E-07	7,99E-04	0	1
6	3,51E-04	0,21	2,20E-07	4,67E-04	3,81E-04	0,23	2,60E-07	5,06E-04	0	1

Fonte: Autoria própria.

No total, a quantidade de dados para a entrada na rede neural é dependente da quantidade de amostras que foram processadas, a quantidade de canais (que é fixa, sempre sendo usados o valor total de 8) e a quantidade de características extraídas do sinal.

#### 5.4 RESULTADOS OBTIDOS DA CLASSIFICAÇÃO POR REDES NEURAIS ARTIFICIAIS

Por fim, nesta seção é apresentado os resultados obtidos da classificação por meio de Redes Neurais Artificiais. Observou-se, durante o seu treinamento, o comportamento do erro como o apresentado na Figura 40. O seu decaimento aproximou-se de zero quase exponencialmente, sem quebras ou interrupções, o qual significa que o método do gradiente está sendo aplicado na busca do mínimo local da função.



**Figura 40 – Gráfico do erro x épocas de um dos treinamentos da MLP.**  
Fonte: Autoria própria.

Os resultados das taxas de acertos da MLP estão apresentados na Tabela 4. Com as taxas de acertos de cada treinamento e teste, são apresentadas as suas respectivas médias e desvios padrões. Ao final, calculou-se a média de todos os resultados e os desvios padrões das respectivas médias correspondentes.

Na Tabela 4, pode-se perceber que a utilização das 4 características forneceram altas taxas de acerto, muita próximas de 100%. Entretanto, as topologias construídas pelo critério de Kolmogorov obtiveram taxas de acerto de 99% na etapa de treinamento e 98% na etapa de validação. Porém, as topologias com Weka obtiveram cerca de 98,3% de acertos na etapa de treinamento e 96% na etapa de teste. Sobre o desvio padrão dos resultados das amostras, as topologias com Weka obtiveram os menores desvios padrões, chegando, em alguns casos, serem nulos. Porém, esses valores ainda assim são muito próximos dos desvios padrões encontrados nas redes por topologia Kolmogorov.

**Tabela 4 – Resultados da média dos acertos e seu desvio padrão entre as etapas de treinamento e de teste da MLP para as quatro características.**

Parâmetro	Média % (Treinamento)		Média % (Teste)		Desvio Padrão (Treinamento)		Desvio Padrão (Teste)		
	K	W	K	W	K	W	K	W	
Topologia									
Conjunto de dados	1	99,07	98,36	97,86	96,14	0,265	0,3912	0,51	0,370
	2	99,04	98,43	98,14	96,29	0,160	0,3194	0,39	0,098
	3	99,11	98,46	97,86	96,43	0,126	0	0,51	0
	4	98,96	98,39	98,14	96,43	0,149	0	0,39	0,098
	5	98,89	98,29	98,00	96,43	0,149	0	0,32	0,080
Total	99,01	98,39	98	96,34	0,077	0,068698	0,143	0,1277753	

**Fonte: Autoria própria.**

Notou-se que o tempo de treinamento de cada topologia foi influenciado pela quantidade de neurônios. Em média, o treinamento da rede por Kolmogorov demorou cerca de 30 segundos, enquanto que por Weka, 6 segundos. Por isso, nestes casos, mesmo que o desempenho das redes pela topologia de Weka sejam ligeiramente menor, seu tempo de execução é muito menor que em comparação a Kolmogorov, o que pode significar uma vantagem ao ser utilizada.

## 5.5 DISCUSSÃO

Sobre todo o panorama descrito e apresentado, o sistema de *armband* apresentou os resultados esperados com base nos objetivos mencionados

anteriormente. As etapas de aquisição, processamento e classificação, aliadas ao sistema físico, conseguiram discernir entre dois movimentos utilizando um único sistema multicanal aliada a fusão de dados de um giroscópio.

O circuito de aquisição, com o INA128, mesmo sendo simples, apresentou bons resultados pelas suas características. Além disso, os dados fornecidos pelo giroscópio auxiliaram a detecção do instante de tempo em que os movimentos são executados. Porém, as maiores dificuldades da parte física do sistema vieram pelo velcro, que não se adaptou a todas as pessoas devido o formato do braço e a sua rigidez intrínseca.

Também no sistema físico, outra questão é o uso das baterias como forma de alimentação, pois como são grandes, os usuários precisaram segurá-las com a mão para poderem realizar os movimentos. O uso de cabos colaborou para que maus contatos ocorressem durante as aquisições. Com relação ao uso dos eletrodos, como foram utilizados eletrodos comerciais com gel, estes foram um dos grandes problemas da aplicação. Após cada uso, os mesmos eram descartáveis, o que gerava um grande número de eletrodos para as medições e em todas as aplicações.

O uso do *software* de LabVIEW™ como plataforma para aquisição e processamento facilitou o armazenamento dos dados e o acompanhamento das informações durante o tratamento dos dados. Com o condicionamento realizado em pelo *software*, diminuiu a quantidade de *hardware* alocado na pulseira, o que poderia deixá-la com maior massa e muitas vezes, de difícil movimentação.

A Rede Neural MLP obteve altos índices de acertos para a detecção dos movimentos, acima de 95%. Para a detecção de uma maior quantidade de movimentos e gestos, podem ser integradas mais características, pertencentes aos domínios da frequência, de tempo-frequência e espaciais, o que demanda análise e estudo.

Por fim, a comparação com o sistema Myo™ obteve bons resultados. Mesmo com o sistema físico ser simples, o mesmo padrão de movimentos pode ser observado. Dessa forma, esse sistema ainda se diferencia do comercial pela possibilidade de alocação tanto nas áreas do braço quanto do antebraço, enquanto que o Myo™ permite apenas alocação no antebraço. Com isso, duas *armbands* poderiam ser usadas em conjunto, uma no antebraço e outra no braço, para o reconhecimento de gestos e movimentos do membro superior forma geral.

## 6 CONSIDERAÇÕES FINAIS

Este trabalho apresentou todo o projeto de construção de um sistema em forma de *armband*, sendo que este é um dos sistemas que mais cresce em aplicações em interfaces homem-máquina utilizando sinais de sEMG. Por meio desse sistema, juntamente com *softwares* de condicionamento, processamento e classificação de sinais, pode-se classificar dois sinais provenientes da ação do braço: flexão e extensão.

Desta forma geral, este trabalho conseguiu atender a todos os objetivos específicos estabelecidos. Primeiramente, foi apresentada uma a revisão dos assuntos pertinentes ao desenvolvimento do trabalho (fisiologia muscular, anatomia do braço, instrumentação de sinais de sEMG, processamento de sEMG, fusão de sensores e redes neurais). Após estes conceitos, a metodologia proposta pode ser efetivamente cumprida, a qual envolvia desde a construção dos circuitos até os passos e procedimentos para a realização dos testes. Posteriormente, foram projetados e implementados circuitos de condicionamento (com etapa de amplificação e filtragem) com um sistema auxiliar de referência inercial (giroscópio), os quais foram conectados à uma placa de aquisição de dados. Terminada as etapas de *hardware*, desenvolveu-se sistemas de aquisição de sinais e de processamento, envolvendo etapas de filtragem digital, segmentação e extração de características do sinal de sEMG. Durante essa etapa, foi montado um banco de dados contendo sinais de flexão e extensão do braço, captado pela *armband*. O último passo foi a construção de Redes Neurais Artificiais para a classificação destes movimentos apenas com as características do sinal de sEMG, contendo taxas de acerto acima de 95% entre as etapas de treinamento e teste.

O sistema apresentado pode ser aplicado para diversos trabalhos anteriormente realizados pelos pesquisadores, como o comando de um braço robótico projetado com um grau de liberdade (SARRO JUNIOR; MENDES JUNIOR; FRANTZ, 2014). Além disso, permite-se novas estruturas de aplicações e de usos devido a versatilidade e facilidade de alocação. Mesmo com seu sistema de aquisição, pode-se perceber que o mesmo pode ser utilizado para a captação de sinais, tais como os sistemas comerciais disponíveis, necessitando de processamento e refinamento na sua estrutura física.



Como um resultado preliminar, a etapa inicial desse estudo gerou uma publicação no XXV Congresso Brasileiro de Engenharia Biomédica, com o título de “Desenvolvimento de *armband* com fusão de sEMG e giroscópio para identificação de grupos musculares do braço”, em 2016. Outros trabalhos derivados desta dissertação e que a complementam são: “*Circuit Design for Surface Electromyography Data Acquisition*”, na Revista do IEEE América Latina, em 2015; “*Robotic Arm Activation using Surface Electromyography with LABVIEW*”, na Revista do IEEE América Latina, em 2016; e “*Neural Network to Failure Classification in Robotic Systems*”, na *Brazilian Journal of Instrumentation and Control*, em 2016.

De uma forma geral, as dificuldades da implementação desses sistemas é a integração de informações, característico da instrumentação biomédica, com informações físicas, químicas, biológicas, eletrônicas e de processamento de sinal.

Como propostas futuras estão o melhoramento do sistema físico em um sistema de condicionamento leve e robusto. Essa parte do projeto leva em consideração o estudo de um tamanho menor de contatos de pressão, os quais possuem o mesmo diâmetro dos eletrodos.

O segundo ponto de estudos futuros baseia-se no desenvolvimento de *softwares* com processamento de pouco atraso de tempo e o teste de novas técnicas de classificação. Por fim, deseja-se implementar uma análise do posicionamento da *armband* no músculo durante a rotação do equipamento, a fim de analisar quais as mudanças que há na aquisição do sinal. Essa análise está relacionada com a criação de um algoritmo para a localização aproximada do grupo muscular que os eletrodos pertencem. Para isso, evitando que uma grande quantidade de eletrodos seja usada e desperdiçada, estuda-se a utilização de eletrodos sem os adesivos, já que estes perdem sua funcionalidade com o decorrer do tempo.

## REFERÊNCIAS

- AHSAN, M. R.; IBRAHIMY, M. I.; KHALIFA, O. O. Neural network classifier for hand motion detection from EMG signal. **IFMBE Proceedings Biomed**, v. 35, p. 536–541, 2011.
- ALLUM, C.; HUSSAIN, S. S.; MALONEY, J. A. **E- $\mu$  Armband**. [s.l.: s.n.]. Disponível em:  
<[http://www.ecs.umass.edu/ece/sdp/sdp15/team18/Resources/FPR\\_Report.pdf](http://www.ecs.umass.edu/ece/sdp/sdp15/team18/Resources/FPR_Report.pdf)>. Acesso em: 10 abr. 2016.
- ANDREONI, G. et al. Human Machine Interface for Healthcare and Rehabilitation. In: YOSHIDA, H.; VAIDYA, S.; JAIN, L. C. (Eds.). . **Advanced Computational Intelligence Paradigms in Healthcare-2**. Studies in Computational Intelligence 65. 1. ed. [s.l.] Springer-Verlag Berlin Heidelberg, 2007.
- ARTEMIADIS, P. K.; KYRIAKOPOULOS, K. J. A Switching Regime Model for the EMG-Based Control of a Robot Arm. **IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)**, v. 41, n. 1, p. 53–63, fev. 2011.
- AU, A. T. C.; KIRSCH, R. F. EMG-based prediction of shoulder and elbow kinematics in able-bodied and spinal cord injured individuals. **IEEE Transactions on Rehabilitation Engineering**, v. 8, n. 4, p. 471–480, dez. 2000.
- AZIZ, A. M. A new adaptive decentralized soft decision combining rule for distributed sensor systems with data fusion. **Information Sciences**, Business Intelligence in Risk Management. v. 256, p. 197–210, 20 jan. 2014.
- BALBINOT, A.; FAVIEIRO, G. A Neuro-Fuzzy System for Characterization of Arm Movements. **Sensors**, v. 13, n. 2, p. 2613–2630, 21 fev. 2013.
- BASHEER, I. A.; HAJMEER, M. Artificial neural networks: fundamentals, computing, design, and application. **Journal of Microbiological Methods**, Neural Computing in Microbiology. v. 43, n. 1, p. 3–31, 1 dez. 2000.
- BASMAJIAN, J. V.; DE LUCA, C. J. **Muscle Alive: Their Functions Revealed by Electromyography**. 5. ed. Baltimore: Williams & Wilkins, 1985.
- BISHOP, C. M. **Neural Networks for Pattern Recognition**. Oxford: Clarendon Press, 1995.
- BLANCA, D. et al. Feasibility of using combined EMG and kinematic signals for prosthesis control: A simulation study using a virtual reality environment. **Journal of Electromyography and Kinesiology**, v. 29, p. 21–27, 2016.

BONATO, P.; D'ALESSIO, T.; KNAFLITZ, M. A statistical method for the measurement of muscle activation intervals from surface myoelectric signal during gait. **IEEE Transactions on Biomedical Engineering**, v. 45, n. 3, p. 287–299, mar. 1998.

BORBÉLY, B. J.; SZOLGAY, P. Estimating the instantaneous wrist flexion angle from multi-channel surface EMG of forearm muscles. In: 2013 IEEE BIOMEDICAL CIRCUITS AND SYSTEMS CONFERENCE (BIOCAS). 2013, Roterdã, Holanda. **Anais...** Roterdã, Holanda, out. 2013

BROCK, E. L. V. D. et al. Affective Man-Machine Interface: Unveiling Human Emotions through Biosignals. In: FRED, A.; FILIPE, J.; GAMBOA, H. (Eds.). . **Biomedical Engineering Systems and Technologies: International Joint Conference, BIOSTEC 2009, Porto, Portugal, January 14-17, 2009, Revised Selected Papers**. [s.l.] Springer Science & Business Media, 2010.

CANNAN, J.; HU, H. A Multi-sensor armband based on muscle and motion measurements. In: 2012 IEEE INTERNATIONAL CONFERENCE ON ROBOTICS AND BIOMIMETICS (ROBIO). 2012, Guangzhou, China. **Anais...** Guangzhou, China, dez. 2012

CARR, J. J.; BROWN, J. M. **Introduction to Biomedical Equipment Technology**. 4. ed. Upper Saddle River, New Jersey: Prentice Hall, 2001.

CARVALHO, L. C. **Instrumentação médico-hospitalar**. São Paulo: Manole, 2008.

CARVALHO, E. G. DE. **Influência da modelagem dos componentes de bias instabilidade dos sensores inerciais no desempenho do navegador integrado SNI/GPS**. Dissertação (Mestrado em Engenharia Elétrica)—Rio de Janeiro, RJ: Instituto Militar de Engenharia, 2011.

CHOJACZYK, A. A. et al. Review and application of Artificial Neural Networks models in reliability analysis of steel structures. **Structural Safety**, v. 52A, p. 78–89, 2010.

CHOWDHURY, R. H. et al. Surface Electromyography Signal Processing and Classification Techniques. **Sensors**, v. 13, n. 9, p. 12431–12466, 17 set. 2013.

COHEN, A. Biomedical Signals: Origin and Dynamic Characteristics; Frequency-Domain Analysis. In: BRONZINO, J. D. (Ed.). . **Biomedical Engineering Handbook**. Boca Raton, Florida: CRC Press, 2000. v. 1p. 3189.

COLLIN, J. et al. Inertial Sensors and Their Applications. In: BHATTACHARYYA, S. S. et al. (Eds.). . **Handbook of Signal Processing Systems**. [s.l.] Springer Science & Business Media, 2013.

COSTANZA, E. et al. EMG as a Subtle Input Interface for Mobile Computing. In: BREWSTER, S.; DUNLOP, M. (Eds.). . **Mobile Human-Computer Interaction - MobileHCI 2004**. Lecture Notes in Computer Science. [s.l.] Springer Berlin Heidelberg, 2004. p. 426–430.

COSTANZA, E. et al. Intimate Interfaces in Action: Assessing the Usability and Subtlety of Emg-based Motionless Gestures. In: SIGCHI CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS. 2007, Nova York, Estados Unidos. **Anais....**.Nova York, Estados Unidos, 2007.

CRAM, J. R. The History of Surface Electromyography. **Applied Psychophysiology and Biofeedback**, v. 28, n. 2, p. 81–91, 2003.

CRISWELL, E. **Cram's Introduction to Surface Electromyography**. Sudbury, Massachussets: Jones And Bartlett Publishers, 2011.

CUARELLI, G. **Estimação de parâmetros da marcha humana a partir de medições feitas por acelerômetros e giroscópios e uso de mecanismo de referência**. Dissertação (Mestrado Profissional em Automação e Controle de Processos)—São Paulo: Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, 2013.

DANGELO, J. G.; FATTINI, C. A. **Anatomia Humana Básica**. 2. ed. São Paulo, SP: Atheneu, 2011.

DE LUCA, C. Electromyography. In: WEBSTER, J. G. (Ed.). . **Encyclopedia of Medical Devices and Instrumentation**. 2. ed. New York: John Wiley Publisher, 2006. v. 2p. 3666.

DE LUCA, C. J. The Use of Surface Electromyography in Biomechanics. **Journal of Applied Biomechanics**, v. 13, p. 135–163, 1997.

DE LUCA, C. J. et al. Filtering the surface EMG signal: Movement artifact and baseline noise contamination. **Journal of Biomechanics**, v. 43, p. 1573–1579, 2010.

ENGLEHART, K.; HUDGINS, B. A robust, real-time control scheme for multifunction myoelectric control. **IEEE Transactions on Biomedical Engineering**, v. 50, n. 7, p. 848–854, jul. 2003.

ENGLEHART, K.; HUDGINS, B.; PARKER, P. A. A wavelet-based continuous classification scheme for multifunction myoelectric control. **IEEE transactions on bio-medical engineering**, v. 48, n. 3, p. 302–311, mar. 2001.

FARRELL, T. R.; WEIR, R. F. A Comparison of the Effects of Electrode Implantation and Targeting on Pattern Classification Accuracy for Prosthesis Control. **IEEE Transactions on Biomedical Engineering**, v. 55, n. 9, p. 2198–2211, 2008.

FELZER, T.; FREISLEBEN, B. HaWCoS: The “Hands-free” Wheelchair Control System. In: FIFTH INTERNATIONAL ACM CONFERENCE ON ASSISTIVE TECHNOLOGIES, 2002, Nova York, Estados Unidos. **Anais...** Nova York, Estados Unidos, 2002.

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

GARDNER, M. W.; DORLING, S. R. Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. **Atmospheric Environment**, v. 32, n. 14–15, p. 2627–2636, 1 ago. 1998.

GREWAL, M. S.; WEILL, L. R.; ANDREWS, A. P. **Global Positioning Systems, Inertial Navigation, and Integration**. 2. ed. USA: John Wiley & Sons, 2007.

GUYTON, A. C.; HALL, J. E. **Tratado de Fisiologia Médica**. 12. ed. Rio de Janeiro, RJ: Elsevier, 2011.

HAKONEN, M.; PIITULAINEN, H.; VISALA, A. Current state of digital signal processing in myoelectric interfaces and related applications. **Biomedical Signal Processing and Control**, v. 18, p. 334–359, abr. 2015.

HAN, J.-S. et al. Development of an EMG-based powered wheelchair controller for users with high-level spinal cord injury. . In: INTERNATIONAL CONFERENCE OF CONTROL, AUTOMATION AND SYSTEMS. 2001, Jeju Island, Coréia do Sul. **Anais...** Jeju Island, Coréia do Sul, 2001.

HARGROVE, L. J.; ENGLEHART, K.; HUDGINS, B. A Comparison of Surface and Intramuscular Myoelectric Signal Classification. **IEEE Transactions on Biomedical Engineering**, v. 54, n. 5, p. 847–853, 2007.

HAYKIN, S. **Redes Neurais Princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.

HENNENBERG, K.-A. Principles of Electromyography. In: BRONZINO, J. D. (Ed.). . **Biomedical Engineering Handbook**. Boca Raton, Florida: CRC Press, 2000. v. 1p. 3189.

HERMENS, H. J. et al. Development of recommendations for SEMG sensors and sensor placement procedures. **Journal of Electromyography and Kinesiology**, v. 10, n. 5, p. 361–374, out. 2000.

HUDGINS, B.; PARKER, P.; SCOTT, R. N. A new strategy for multifunction myoelectric control. **IEEE transactions on bio-medical engineering**, v. 40, n. 1, p. 82–94, jan. 1993.

JAMAL, M. Z. Signal Acquisition Using Surface EMG and Circuit Design Considerations for Robotic Prosthesis. In: NAIK, G. R. (Ed.). . **Computacional Intelligence in Electromyography Analysis - A Perspective on Current Applications and Future Challenges**. [s.l.] InTech, 2012.

KAMEN, G.; GABRIEL, D. **Fundamentos da Eletromiografia**. São Paulo: Phorte Editora, 2015.

KANDEL, E. R.; BARRES, B. A.; HUDSPETH, A. J. Nerve Cells, Neural Circuitry, and Behavior. In: KANDEL, E. R. et al. (Eds.). . **Principles of Neural Science**. 5. ed. [s.l.] McGraw-Hill, 2013. p. 1760.

KHEZRI, M.; JAHED, M. Real-time intelligent pattern recognition algorithm for surface EMG signals. **BioMedical Engineering OnLine**, v. 6, p. 45, 3 dez. 2007.

KITCHIN, C.; COUNTS, L. **A Designer's Guide to Instrumentation Amplifiers**. 3 ed ed. USA: Analog Devices, 2006.

LABRADOR, M. A.; YEJAS, O. D. L. **Human Activity Recognition: Using Wearable Sensors and Smartphones**. Boca Raton, Florida: CRC Press, 2013.

LAFERRIERE, P.; CHAN, A. D. C.; LEMAIRE, E. D. Surface electromyographic signals using a dry electrode. In: 2010 IEEE INTERNATIONAL WORKSHOP ON MEDICAL MEASUREMENTS AND APPLICATIONS PROCEEDINGS (MEMEA). 2010, Bari, Itália. **Anais...** Bari, Itália, abr. 2010

LI, G. et al. Selection of Sampling Rate for EMG Pattern Recognition Based Prosthesis Control. In: 2010 ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY. 2010, Buenos Aires, Argentina. **Anais...**Buenos Aires, Argentina: Ago - 4 Set 2010

LI, G. et al. Conditioning and Sampling Issues of EMG Signals in Motion Recognition of Multifunctional Myoelectric Prostheses. **Annals of Biomedical Engineering**, v. 39, n. 6, p. 1779–1787, 2011.

LI, G. Electromyography Pattern-Recognition-Based Control of Powered Multifunctional Upper-Limb Prostheses. In: MIZRAHI, J. (Ed.). . **Advances in Applied Electromyography**. [s.l.] InTech, 2011.

LUO, R. C.; CHANG, C. C. Multisensor Fusion and Integration: A Review on Approaches and Its Applications in Mechatronics. **IEEE Transactions on Industrial Informatics**, v. 8, n. 1, p. 49–60, fev. 2012.

LUO, R. C.; CHANG, C. C.; LAI, C. C. Multisensor Fusion and Integration: Theories, Applications, and its Perspectives. **IEEE Sensors Journal**, v. 11, n. 12, p. 3122–3138, dez. 2011.

MARTIN, H. et al. A novel approach of prosthetic arm control using computer vision, biosignals, and motion capture. In: 2014 IEEE SYMPOSIUM ON COMPUTATIONAL INTELLIGENCE IN ROBOTIC REHABILITATION AND ASSISTIVE TECHNOLOGIES (CIR2AT) 2014, Orlando, Estados Unidos. **Anais...** Orlando, Estados Unidos, dez. 2014.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, n. 4, p. 115–133, 1943.

MENDES JR., J. J. A. et al. Sensor Fusion and Smart Sensor in Sports and Biomedical Applications. **Sensors**, v. 16, n. 10, p. 1569, 23 set. 2016.

MERLETTI, R. et al. Technology and instrumentation for detection and conditioning of the surface electromyographic signal: State of the art. **Clinical Biomechanics**, v. 24, n. 2, p. 122–134, 2009.

MERLETTI, R.; HERMENS, H. J. Detection and Conditioning of the Surface EMG Signal. In: MERLETTI, R.; PARKER, P. (Eds.). . **Electromyography: Physiology, Engineering, and Noninvasive Applications**. Piscataway, New Jersey: John Wiley & Sons, 2004. p. 494.

MOON, I. et al. Wearable EMG-based HCI for Electric-Powered Wheelchair Users with Motor Disabilities. In: 2005 IEEE INTERNATIONAL CONFERENCE ON ROBOTICS AND AUTOMATION. 2005, Barcelona, Espanha. **Anais...** Barcelona, Espanha: IEEE, abr. 2005.

MORI, A. M. **O uso de sistema inercial para apoiar a navegação autônoma**. Dissertação (Mestrado em Ciências)—São Paulo, SP: Escola Politécnica da Universidade de São Paulo, 2013.

MORSE, M. S. et al. Use of myoelectric signals to recognize speech. In: ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 1989. IMAGES OF THE TWENTY-FIRST CENTURY. 1989, Seattle, Estados Unidos. **Anais...** Seattle, Estados Unidos: nov. 1989

NAGEL, J. H. Biopotential Amplifiers. In: **Biomedical Engineering Handbook**. Boca Raton, Florida: CRC Press, 2000. v. 1p. 1364–1377.

NAJARIAN, K.; SPLINTER, R. **Biomedical signal and image processing**. 2. ed. Florida, US: CRC Press, 2012.

NALON, J. A. **Introdução ao Processamento Digital de Sinais**. Rio de Janeiro, RJ: LTC, 2014.

NATIONALS INSTRUMENTS. **Bus-Powered M Series Multifunction DAQ for USB - 16-Bit, up to 400 kS/s, up to 32 Analog Inputs, Isolation**, 6 nov. 2014. Disponível em: <<http://www.ni.com/datasheet/pdf/en/ds-9>>. Acesso em: 3 jun. 2016

NAZMI, N. et al. A Review of Classification Techniques of EMG Signals during Isotonic and Isometric Contractions. **Sensors**, v. 16, n. 8, p. 1304, 17 ago. 2016.

NEUMAN, M. R. Biopotential Amplifiers. In: WEBSTER, J. G. (Ed.). . **Medical Instrumentation: Application and Design**. 4. ed. USA: John Wiley & Sons, 2010. p. 713.

OLSON, W. H. Electrical Safety. In: WEBSTER, J. G. (Ed.). . **Medical Instrumentation: Application and Design**. 4. ed. USA: John Wiley & Sons, 2010. p. 717.

OPPENHEIM, A. V.; SCHAFER, R. W. **Discrete-Time Signal Processing**. Englewood Cliffs, NJ: Prentice-Hall, 1989.

OPPENHEIM, A. V.; WILLSKY, A. S. **Sinais e Sistemas**. 2. ed. São Paulo, SP: Pearson, 2010.

OSKOEI, M. A.; HU, H. Myoelectric control systems - a survey. **Biomedical Signal Processing and Control**, v. 2, n. 4, p. 275–294, Out 2007.

OSKOEI, M. A.; HU, H. Support vector machine-based classification scheme for myoelectric control applied to upper limb. **IEEE transactions on bio-medical engineering**, v. 55, n. 8, p. 1956–1965, ago. 2008.

PEDROSO, L. J. DE G. R. **Avaliação dos efeitos sobre os estimadores eletromiográficos de diversos métodos de filtragem da interferência da rede elétrica**. Dissertação—Brasília: Universidade de Brasília, 2013.

PHINYOMARK, A.; PHUKPATTARANONT, P.; LIMSAKUL, C. Feature reduction and selection for EMG signal classification. **Expert Systems with Applications**, v. 39, n. 8, p. 7420–7431, 15 jun. 2012.

POZZO, M.; FARINA, D.; MERLETTI, R. Electromyography: Detection, Processing and Applications. In: MOORE, J.; ZOURIDAKIS, G. (Eds.). . **Biomedical Technology and Devices Handbook**. Boca Raton, Florida: CRC Press, 2004. p. 776.

ROSEN, J.; FUCHS, M. B.; ARCAN, M. Performances of Hill-Type and Neural Network Muscle Models—Toward a Myosignal-Based Exoskeleton. **Computers and Biomedical Research**, v. 32, n. 5, p. 415–439, 1 out. 1999.

SARRO JUNIOR, A. D.; MENDES JUNIOR, J. J. A.; FRANTZ, S. H. **Controle de um braço de robótico através de Eletromiografia**. 110f. Trabalho de Conclusão de Curso - Tecnologia em Automação Industrial, Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2014.



SAPONAS, T. S. et al. Making Muscle-Computer Interfaces More Practical. In: PROCEEDINGS OF THE SIGCHI CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS. 2010, Atlanta, Estados Unidos. **Anais...** Atlanta, Estados Unidos: 2010.

SAUTER, W. F. et al. Prosthesis with electro elbow and hand for a three-year-old multiply handicapped child. **Prosthetics and Orthotics International**, v. 9, p. 105–108, 1985.

SENANAYAKE, S. M. N. A. et al. 3-D kinematics and neuromuscular signals' integration for post ACL reconstruction recovery assessment. In: 2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). 2013, Osaka, Japão. **Anais...** Osaka, Japão, jul. 2013

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

SMITH, S. W. **The Scientist and Engineer's Guide to Digital Signal Processing**. 2. ed. San Diego, California, EUA: California Technical Publishing, 1999.

SPULBER, I. et al. Development of a wireless multi-functional body sensing platform for smart garment integration. In: 2014 IEEE BIOMEDICAL CIRCUITS AND SYSTEMS CONFERENCE (BIOCAS) PROCEEDINGS. 2014, Lausane, Suíça. **Anais...**Lausane, Suíça, out. 2014

ST MICROELECTRONICS. **L3G4200D MEMS motion sensor: ultra-stable three-axis digital output gyroscope**, dez. 2010. Disponível em: <<http://www.st.com/content/ccc/resource/technical/document/datasheet/04/46/d6/00/be/d9/46/ae/CD00265057.pdf/files/CD00265057.pdf/jcr:content/translations/en.CD00265057.pdf>>. Acesso em: 20 jan. 2016

STEVAN JR, S. L. et al. Circuit Design for Surface Electromyography Data Acquisition. **IEEE Latin America Transactions**, v. 13, n. 10, p. 3193–3200, out. 2015.

STEVAN JR., S. L.; SILVA, R. A. **Automação e Instrumentação Industrial com Arduino: Teorias e Projetos**. São Paulo: Érica, 2015.

TEXAS INSTRUMENTS. **INA12x Precision, Low Power Instrumentation Amplifiers**. Texas Instruments, , 1995. Disponível em: <<http://www.ti.com/lit/ds/symlink/ina129.pdf>>. Acesso em: 1 jul. 2016

THALMIC LABS. **Technical Specifications**. Disponível em: <<https://www.myo.com/techspecs>>.

TORTORA, G. J.; DERRICKSON, B. **Corpo Humano : Fundamentos de anatomia e fisiologia**. 8. ed. São Paulo, SP: Artmed, 2012.

TOUCH BIONICS. **History**. Disponível em:  
<<http://www.touchbionics.com/about/history>>.

TRIPLETT, N. T. Structure and Function of Body Systems. In: HAFF, G. G.; TRIPLETT, N. T. (Eds.). . **Essentials of Strength Training and Conditioning**. 4. ed. Champaign, Illinois: Human Kinetics, 2015. p. 752.

TRONTELJ, J. V.; JABRE, J.; MIHELIN, M. Needle and wire detection techniques. In: MERLETTI, R.; PARKER, P. (Eds.). . **Electromyography: Physiology, Engineering, and Noninvasive Applications**. Piscataway, New Jersey: John Wiley & Sons, 2004. p. 494.

TSAI, A.-C. et al. A comparison of upper-limb motion pattern recognition using EMG signals during dynamic and isometric muscle contractions. **Biomedical Signal Processing and Control**, v. 11, p. 17–26, maio 2014.

WEBSTER, J. G. Amplifiers and signal processing. In: WEBSTER, J. G. (Ed.). . **Medical Instrumentation: Application and Design**. 4. ed. USA: John Wiley & Sons, 2010. p. 717.

XIE, H.-B. et al. Hybrid soft computing systems for electromyographic signals analysis: a review. **BioMedical Engineering OnLine**, v. 13, p. 8, 2014.

XU, L.; ADLER, A. An improved method for muscle activation detection during gait. In: 2004 CANADIAN CONFERENCE ON ELECTRICAL AND COMPUTER ENGINEERING. 2004, Ontario, Canadá. **Anais...** Ontário, Canadá, maio 2004

YOUNG, A. J.; HARGROVE, L. J.; KUIKEN, T. A. Improving Myoelectric Pattern Recognition Robustness to Electrode Shift by Changing Interelectrode Distance and Electrode Configuration. **IEEE Transactions on Biomedical Engineering**, v. 59, n. 3, p. 645–652, 2012.

ZHANG, X. et al. A Framework for Hand Gesture Recognition Based on Accelerometer and EMG Sensors. **IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans**, v. 41, n. 6, p. 1064–1076, nov. 2011.

ZHAO, J. et al. EMG Control for a Five-fingered Underactuated Prosthetic Hand Based on Wavelet Transform and Sample Entropy. In: 2006 IEEE/RSJ INTERNATIONAL CONFERENCE ON INTELLIGENT ROBOTS AND SYSTEMS. 2006, Pequim, China. **Anais...** Pequim, China, out. 2006

**APÊNDICE A** - Instrumento Virtual de aquisição dos dados de sEMG e do giroscópio em LabVIEW

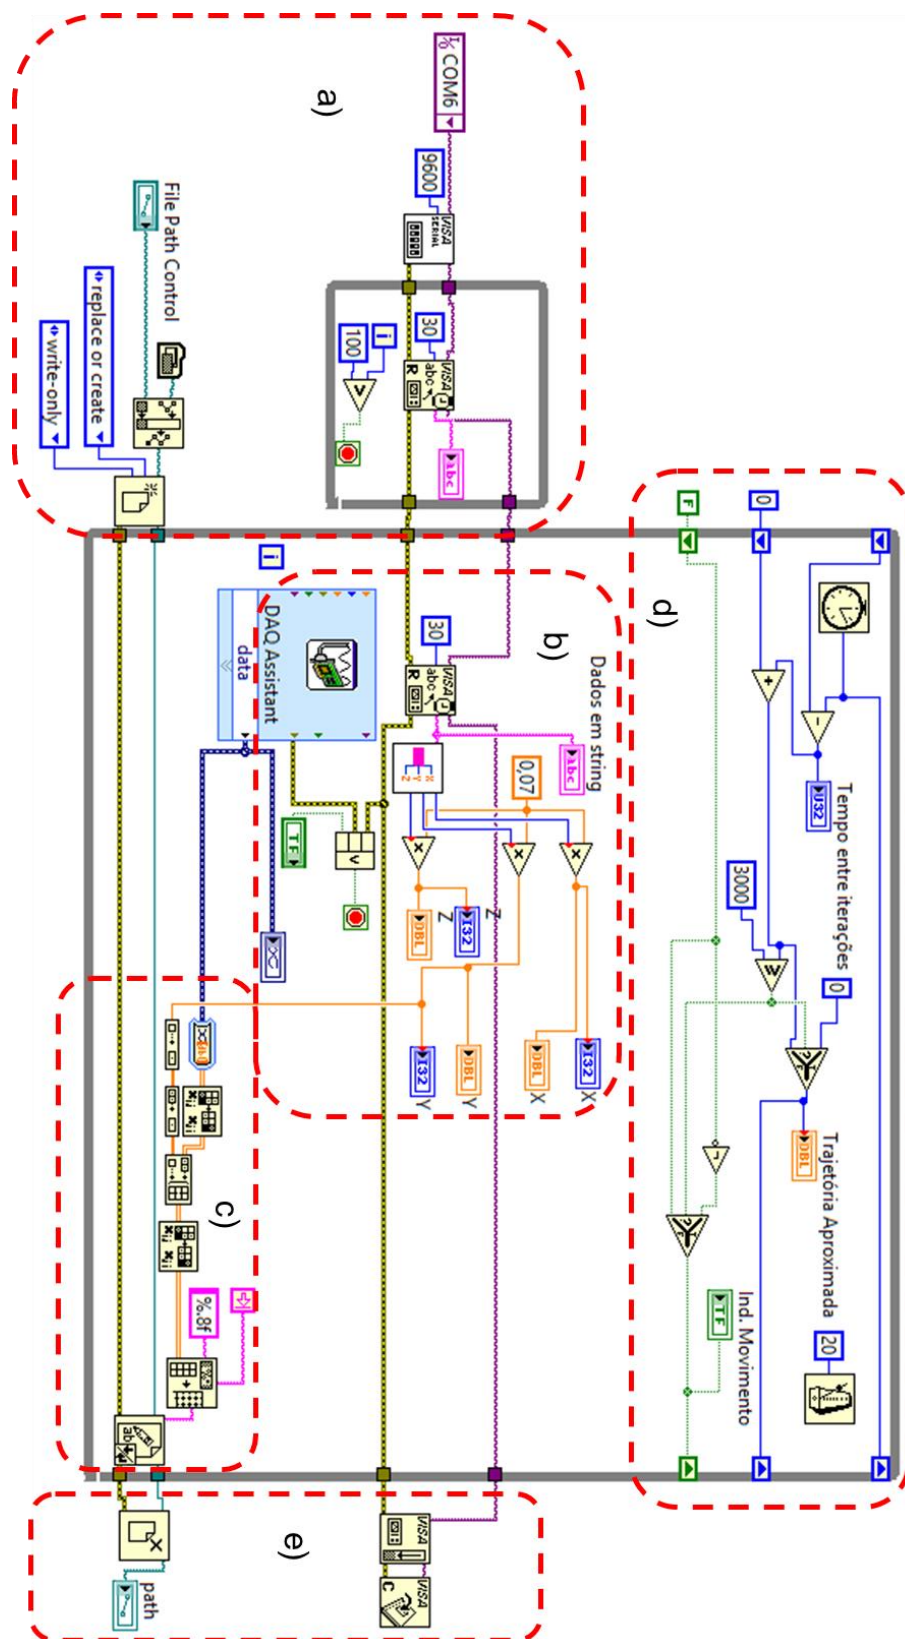


Figura 41 –Diagrama de blocos do sistema de aquisição, estando destacadas: a) suas configurações iniciais, b) aquisição dos dados, c) rotina de salvamento, d) temporização e orientação ao indivíduo e e) configurações finais.

Fonte: Autoria própria.

A primeira etapa do programa é a configuração dos parâmetros iniciais (Figura 41a), em que são configuradas simultaneamente tanto os comandos da porta serial (leitura do giroscópio) quanto do arquivo em .txt (onde serão guardados os dados). A comunicação serial é iniciada com o *baudrate* da transmissão (9600) e com o nome da porta (COM 6). Com estes valores, o programa entre em um pequeno *loop while* que aguarda a inicialização do giroscópio. Este *loop* foi definido para rodar 100 vezes, até se ter garantia de que os dados do sensor inercial estão realmente chegando ao programa e não houve problema durante a transmissão/conexão. Estes dados recebidos são apresentados no Painel Frontal em formato de texto (*string*).

Por sua vez, os blocos inferiores da seção a) são responsáveis por criar um arquivo de texto em branco para salvar os dados dessa aquisição. O nome do arquivo é inserido pelo usuário (no campo *File Path Control*) no painel frontal, o qual é adicionado ao caminho em que o VI está salvo. O próximo passo foi criar um arquivo novo ou substituí-lo (se não for alterado o nome do arquivo anteriormente pelo usuário), bem como permitir apenas a operação de escrita dos dados (pois a leitura será feita em uma etapa posterior).

A partir dessas configurações, a programação segue para um *loop* central, em que passará a maior parte do seu tempo. Nele, pela ordem da chegada dos dados, dá-se prosseguimento a etapa de aquisição (Figura 41b). Os dados chegam por meio de dois blocos principais: *DaqAssistant* e *Read Serial*.

O bloco *DaqAssistant* possui conectividade direta com a placa NIDAQ USB-6212. Nele estão configurados a leitura dos oito canais, sua forma de referência (RSE para as aplicações *single-ended*), faixa dinâmica do sinal de  $\pm 5$  V, frequência de amostragem de 2 kHz e número de amostras de 40. Estes dois últimos valores são de extrema importância para se definir o tempo que levará para cada iteração deste *loop While* central operar. A frequência de atualização dos dados segue a multiplicação direta entre esses dois valores, pois cada iteração irá entregar 40 amostras de cada um dos oito canais adquiridas em um tempo de 0,5 ms (período de amostragem correspondente a 2 kHz). Dessa forma, a frequência de atualização do sistema torna-se 50 Hz, o qual é a mesma que a definida para o giroscópio, sincronizando os dois sistemas de aquisição. O sinal de sEMG pode ser visto por meio de um gráfico no Painel frontal.


Por sua vez, o bloco *Read Serial* faz a leitura da porta serial, sendo configurada para armazenar em *buffer* mensagens de até 30 bytes. É necessário

inserir esse valor para que o bloco possa receber e apresentar estes dados; sendo 30 o maior número de bytes que o giroscópio foi programado para enviar. Quando este valor estoura, o bloco apenas apresenta os 30 bytes no total, não apresentando a outra parte da mensagem. Nessa aplicação, isso não ocorre devido ao tamanho da mensagem final.

A saída do bloco de leitura dá-se por meio de uma *string* de texto única. Essa *string* é direcionada para uma subrotina (subVI), que extrai um número a partir da *string* de texto. A Figura 42a mostra o símbolo desse subVI, enquanto que a Figura 42b, o seu diagrama de blocos interno. Como seu próprio símbolo, ela retira os valores da velocidade angular nos eixos X, Y, e Z da mensagem da serial. Para selecionar os dados, faz-se uso da função *Search/Split String*, a qual procura um determinado caractere em uma *string* e a divide entre antes e depois desse caractere. Após cada mensagem ser dividida entre seus endereços e valores, os dados referentes ao endereçamento foram retirados por meio de um *offset* de 1 caractere, realizado pela função *String Subset*. Com os dados separados, estes são convertidos em valores numéricos por meio da função *Decimal String to Number*, resultando em um valor em números inteiros.

Separados os dados, estes são multiplicados pela constante adimensional 0,07 para retornar seus valores em velocidade angular. Estes valores são apresentados em indicadores numéricos e gráficos.

Nota-se ainda, nessa estrutura do código, a junção de três sinais (dois provenientes de alertas de erro do *DaqAssistant* e do *Serial Read*) com um sinal booleano proveniente de um botão de parada (*stop*) em uma porta lógica “ou”. Essa lógica está atrelada ao botão de parada do *loop While*, que irá parar a sua execução quando houver erro nas rotinas de execução ou quando o usuário solicitar parar a aquisição dos dados.



**Figura 42 – SubVI de separação dos dados do giroscópio, sendo a) seu símbolo e b) seu diagrama de blocos.**

**Fonte: Autoria própria.**

A terceira parte da programação (Figura 41c) é dedicada a organização dos dados para sua posterior gravação. O primeiro passo é a conversão dos dados da saída do DaqAssistant (que estão em formato de dados dinâmicos, DDT, *Dynamic Data*) para valores numérico, em colunas e linhas organizadas (em formato de *array*). Após essa conversão, os dados provenientes do eixo Y do giroscópio são transformados em formato de *array* e reunidos em um único *array*. Por sua vez, os dados são transformados para uma planilha em forma de *string*, por meio do bloco *Array to Spreadsheet String*, definindo uma tabulação simples como seu delimitador. Por fim, os dados foram enviados para a função *Write to Text File*, que escreve os dados da planilha em formato no arquivo previamente criado/aberto. A cada iteração do *loop while*, o arquivo de texto é acrescido com as informações.

As rotinas para orientação do indivíduo e do controle de tempo estão presentes na seção d) da Figura 41. Na parte superior, utiliza-se um bloco de *Tick Count*, que calcula o tempo de cada iteração por meio de uma subtração entre dois tempos consecutivos. A atualização destes dados para essa operação é feita por meio da função *Shift Register*. Essa função retorna para a entrada do *While* o valor inserido na sua respectiva saída, fazendo o *feedback* da informação. O tempo de cada iteração é incrementado utilizando um somador até o valor especificado em milissegundos (3000 nesse caso) para a duração de cada movimento. Esse tempo é apresentado no indicador de trajetória aproximada, auxiliando a pessoa a fazer o movimento, além da utilização de um indicador booleano para indicar se é flexão ou extensão. Ao chegar no valor de tempo especificado, duas funções *Select* alteram os valores dos indicadores, reiniciando o marcador de trajetória e invertendo o estado booleano do movimento. O último bloco dessa etapa está localizado no canto superior direito, o *Wait until Next Multiple*, com uma constante de 20 em sua entrada. A função desse

bloco é garantir a sincronia de tempo entre toda a iteração do *loop while*. Com cada iteração terá 20 ms de tempo, esse bloco calcula quanto foi a duração de tempo de todas as funções executadas anteriormente e aguarda o período de tempo necessário para se completar 20 ms, garantindo assim um intervalo de tempo fixo.

As últimas funções (Figura 41e) referem-se as configurações finais do programa. Na parte superior, tem-se o fechamento da porta serial, com as funções de *VISA Flush I/O Buffer* (que apaga todas as informações que estejam no *buffer*) e *VISA Close* (que fecha a porta serial). Por fim, para fechar o arquivo em que os dados estão salvos é utilizada a função *Close File*, além de apresentar o diretório em que o mesmo está salvo.



**APÊNDICE B** - Instrumento Virtual de condicionamento e processamento do sinal de sEMG em LabVIEW

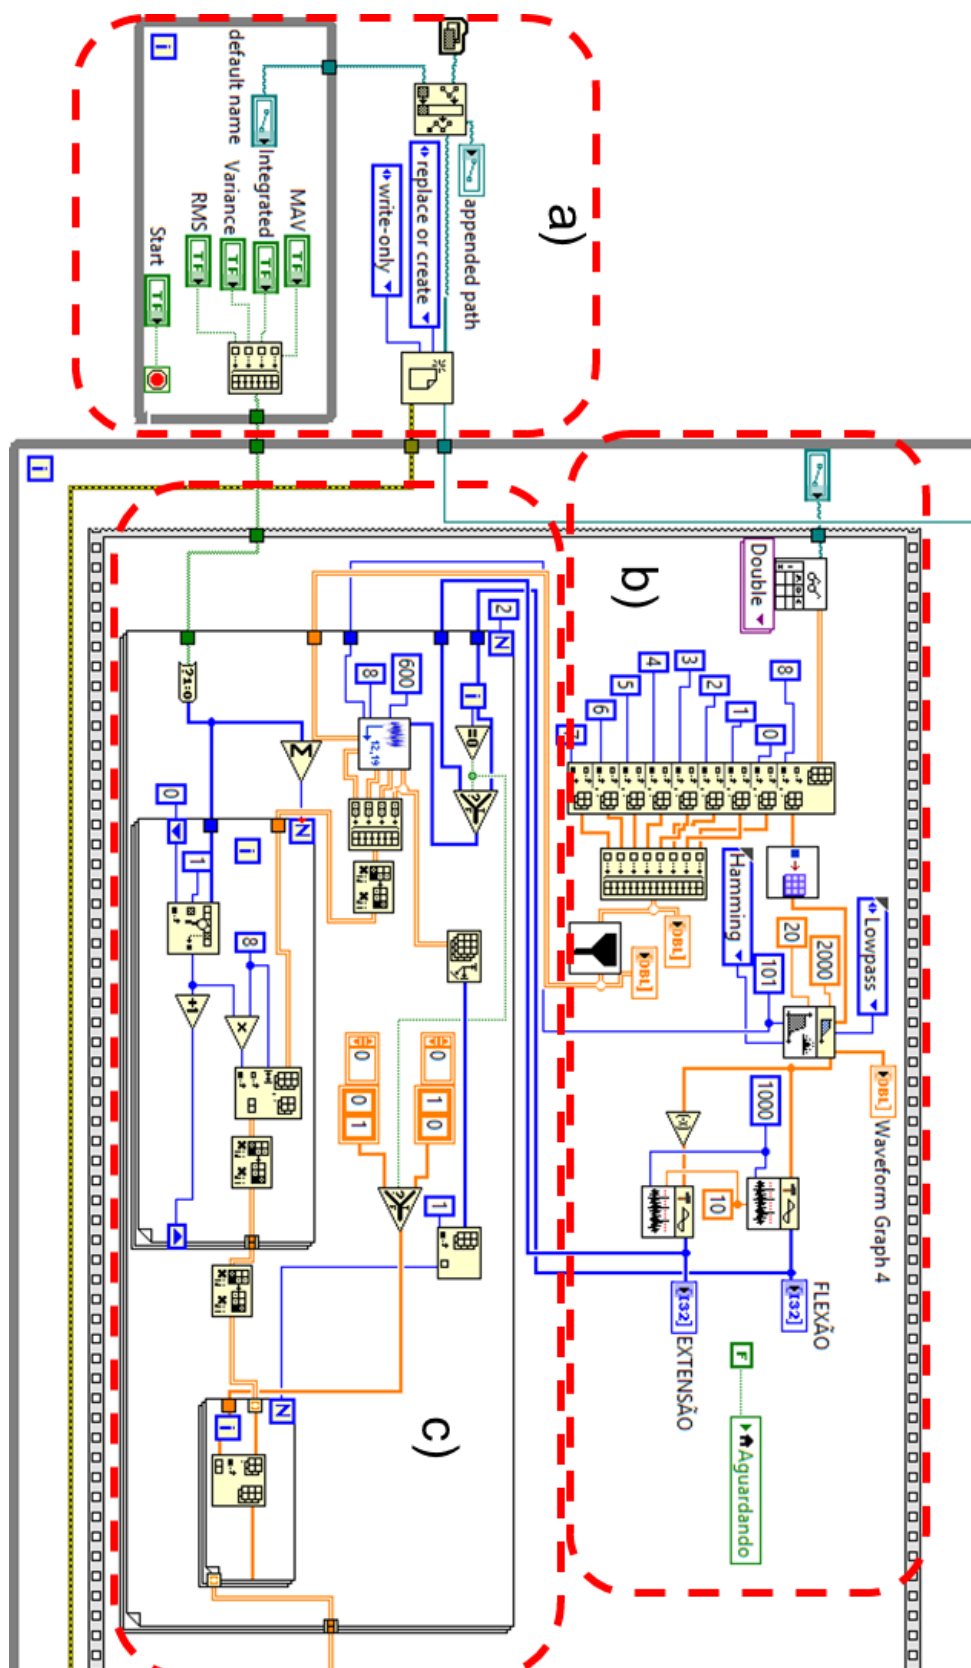


Figura 43 – Parte inicial do diagrama de blocos do sistema de segmentação e extração de características, em destaque, as rotinas de a) abertura do arquivo de aquisição, b) condicionamento dos dados, c) segmentação e extração de características.

Fonte: Autoria própria.

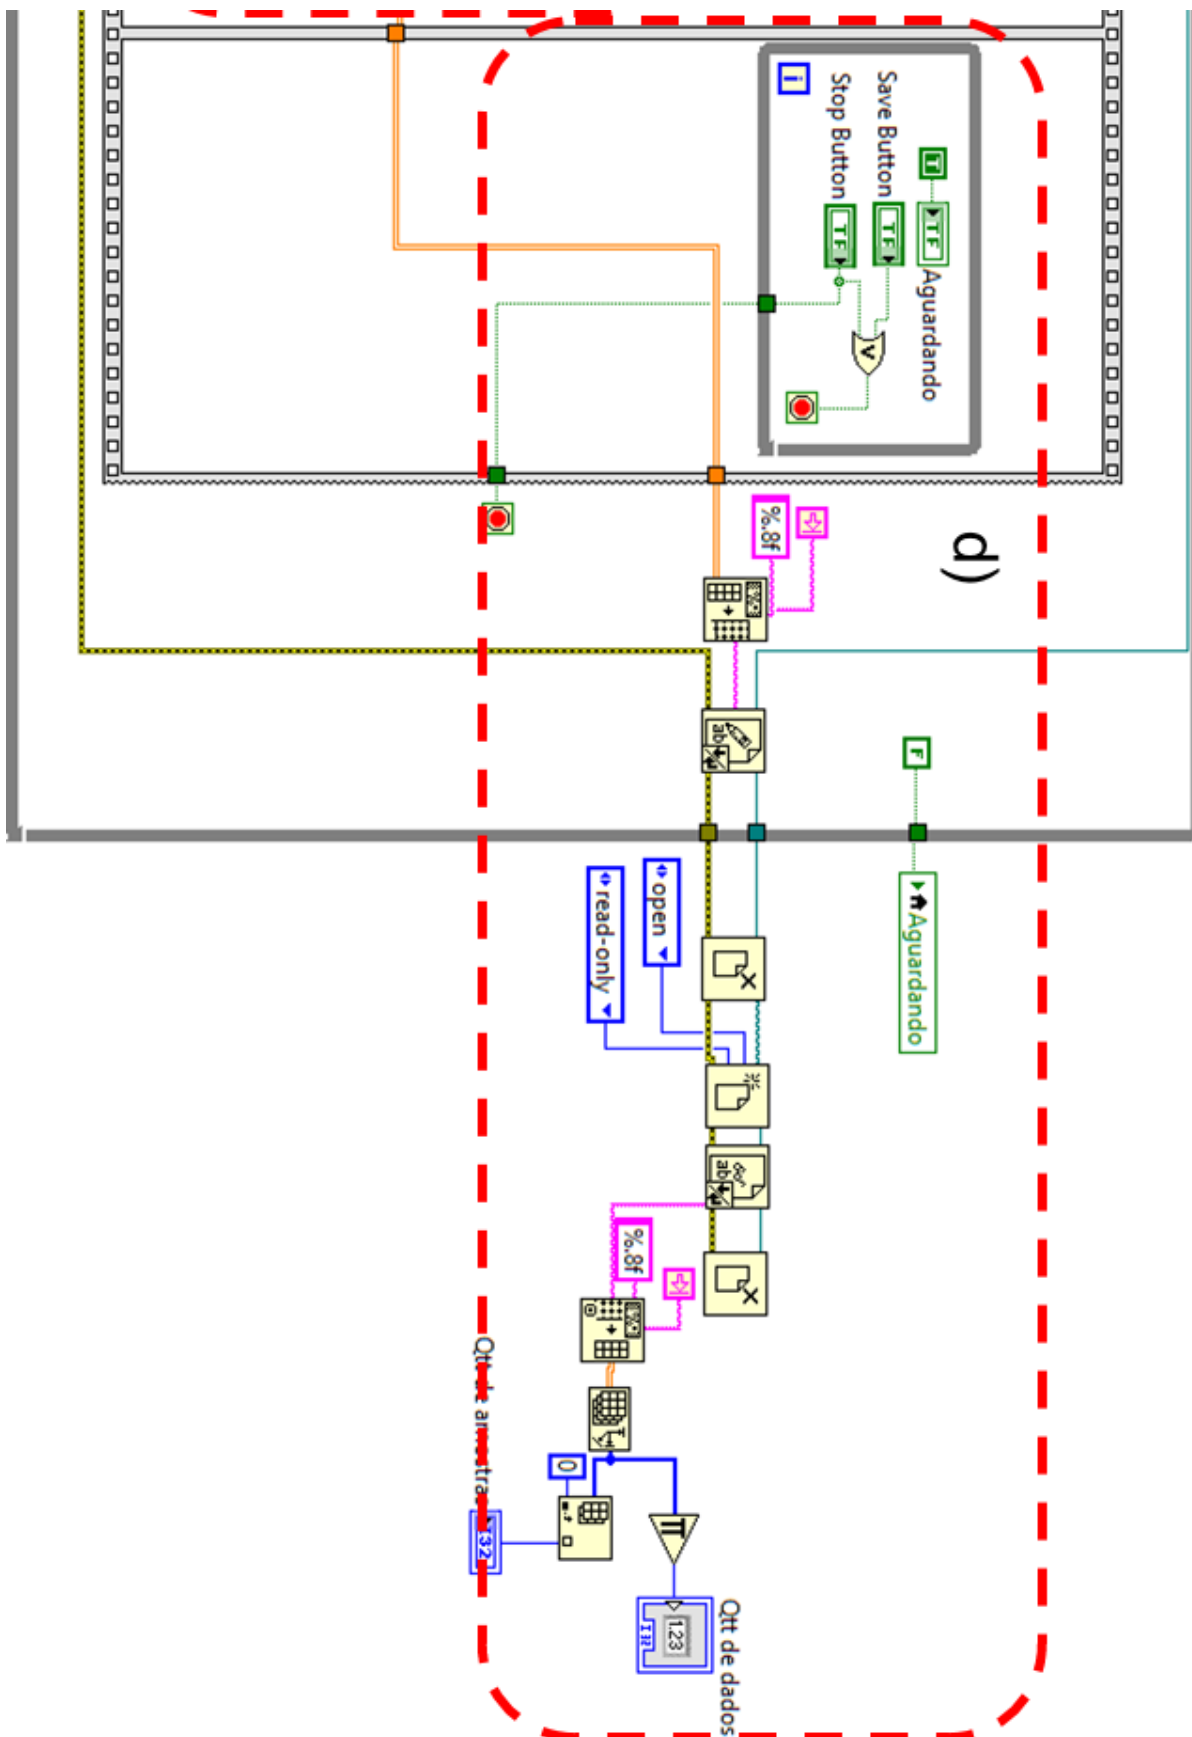


Figura 44 – Parte final do diagrama de blocos do sistema de segmentação e extração de características, em destaque, as rotinas de d) laços de repetição e gravação dos dados. Fonte: Autoria própria.

As Figuras 43 e 44 apresentam o diagrama de blocos da aplicação de condicionamento e processamento. De uma forma geral, a operação ocorre da seguinte forma: escolhe-se as características que se deseja extrair e o nome do arquivo que os dados vão ser salvos; seleciona-se o arquivo em que os dados estão inseridos; inicia-se o processamento; apresentam-se os dados em gráficos e indicadores, sendo atualizados a cada novo arquivo; e por fim, seleciona-se o comando de parada do processamento e grava-se os dados para classificação.

Na Figura 43a, estão presentes as inicializações para a abertura de arquivos e um *loop While* para a escolha das características a serem extraídas do sinal. O programa só inicia após o usuário inserir as características que deseja, bem o nome do arquivo final que saíra desse VI.

As informações definidas anteriormente são encaminhadas para um *loop While* central, o qual possui uma *Flat Sequence*. Essa estrutura de programação executa as rotinas definidas pelo usuário, muito utilizada para criar laços de dependências de variáveis e operações. São inseridos na *Flat Sequence* as informações das características e o caminho do arquivo contendo os dados para a extração. Esses dados pertencem a rotina de condicionamento (Figura 43a). O recebimento destes dados vem por meio de um bloco *Read Spreadsheet*, o qual já transforma numericamente os dados de *string*. Foi usada essa função pela sua facilidade da execução, bem como para não atrasar rotinas de gravação principal (as quais são feitas por meio dos comandos *File*). Os dados, em formato numérico, são separados entre sinais do giroscópio e dos canais de sEMG.

O sinal do giroscópio é, primeiramente, igualado na quantidade de pontos com o sinal de sEMG. Para isso, é utilizada o subVI apresentado na Figura 45a). Nessa subrotina (Figura 45b), cada valor do giroscópio é acrescido em um total de 40 dados (correspondentes da resultante entre os períodos de tempo entre a aquisição do giroscópio e do sEMG). A operação ocorre em um *loop For*, que executa o número de vezes de interação pela quantidade de dados do giroscópio, acrescentando dados em um *array*, o qual corresponde no vetor de saída.

Uma vez ajustados, os dados do giroscópio são direcionados para um filtro FIR passa-baixa para atenuar as componentes de alta frequência, deixando o sinal mais suavizado. Como parâmetros, escolheu-se a configuração janelada, com uma frequência de corte de 20 Hz, 101 coeficientes (*taps*) e aproximação da janela de Hamming (que foi escolhida por experimentação após análise das outras janelas,




Figura 45 – SubVI de ajuste dos *array* do giroscópio, sendo a) seu símbolo e b) seu diagrama de blocos.

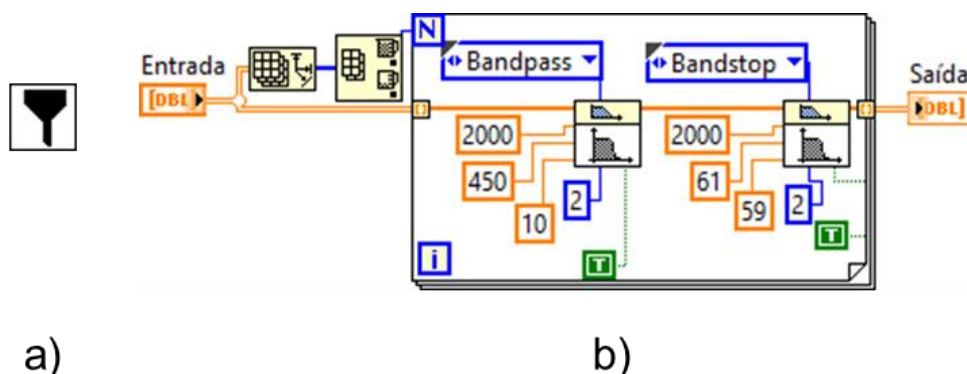
Fonte: Autoria própria.

comparando a sua resposta de amplitude).

A suavização oferecida por esse filtro torna-se importante para a etapa seguinte: a análise de *threshold* do giroscópio para a identificação do momento em que houve movimento. Tal análise é feita utilizando dois blocos de análise de *Threshold*, sendo apresentado para um os dados tal como saíram do filtro e outro com os dados com suas magnitudes invertidas. Isso ocorre porque são analisadas tanto as passagens pelos limiares positivos (flexão) quanto o negativo (extensão) quando ultrapassam o valor de 10 graus/segundo. Além disso, é estipulado um determinado valor (1000) em que esses dados devem se manter acima do patamar para não serem criados falsos positivos. A saída dos blocos de *Threshold* apresentam os valores dos índices os quais os sinais ultrapassaram esse limiar, sendo divididos nos *arrays* flexão e extensão.

Enquanto são processados os dados do giroscópio, os dados de sEMG são condicionados paralelamente por meio da rotina de filtragem presente na Figura 53a. O seu diagrama de blocos (Figura 46b) é composto por um *loop For* com dois blocos de filtragem. Seguindo as instruções previamente citadas, foram utilizados um filtro passa-banda (com frequências de corte passa-alta de 10 Hz e passa-baixa 450 Hz) e *notch* (rejeita faixa nas bandas de 59-61 Hz). Ambos os filtros são de características IIR, aproximação *Butterworth* e de segunda ordem, que selecionam a faixa do sinal e reduzem a influência do ruído da rede elétrica (60 Hz). A escolha dos filtros IIR é devido ao baixo número de coeficientes utilizados em relação a um FIR com as mesmas características de saída, os quais muitas vezes são implementados via *hardware* e muito presentes na literatura no que se relata de processamento de sEMG, bem como sobre a sua aproximação *Butterworth* com resposta plana (MERLETTI et al., 2009). A constante booleana (*True*) permite que os dados não sejam reiniciados sempre, para que não se comece do zero, gerando um pequeno atraso no domínio do

tempo do sinal. A quantidade de iterações é definida pela quantidade de canais (na distribuição entre linhas e colunas, será sempre o menor valor).



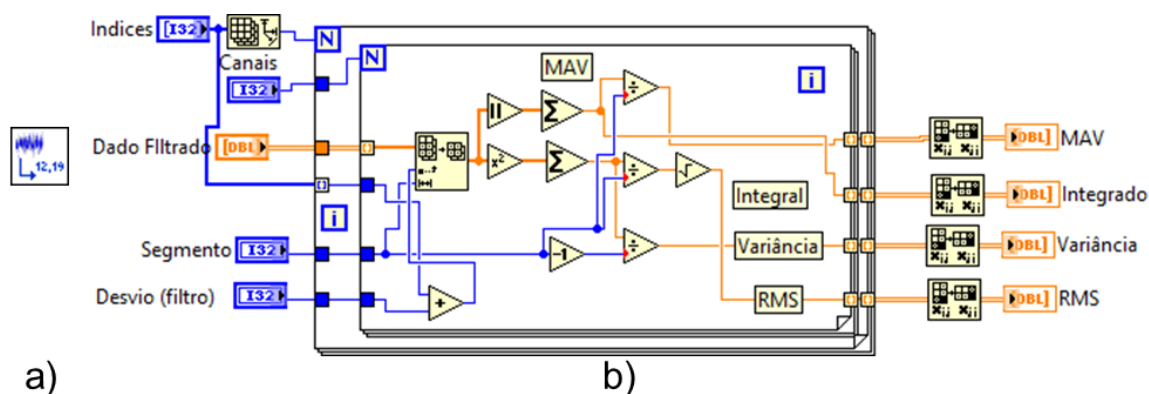
**Figura 46 – SubVI de condicionamento do sinal de sEMG, sendo a) seu símbolo e b) seu diagrama de blocos.**

**Fonte: Autoria própria.**

Com os todos os dados condicionados, o programa passa para a rotina de segmentação e extração de características (Figura 43c). A princípio, é composta por um *loop For* que possui duas iterações: a primeira para a separação dos sinais da flexão e outra para extensão. Se for a primeira iteração (ou seja, iteração igual a zero), os dados da flexão entram na subrotina que separa os dados e calcula suas características, apresentado na Figura 47a. Além disso, como entrada são colocadas a quantidade de canais (8), o número de coeficientes do filtro FIR e número de dados para serem segmentados. O parâmetro do número de coeficientes foi acrescentado a rotina para que se desloque a quantidade de amostras para maior exatidão do sinal a ser coletado, já que o uso de filtros FIR possuem essa vantagem. Não foi considerado o atraso dos sinais dos filtros IIR, se os mesmos fossem construídos em *hardware*, possuiriam os mesmos tempos de atrasos, os quais resultariam em instantes de tempo semelhantes. O período de tempo foi definido foi de 300 ms, o qual resulta em segmentos com 600 amostras de entrada, baseado em estudos de Englehart e Hudgins (2003).

Na Figura 47b, os dados o diagrama de blocos apresenta dois *loops For*. O primeiro tem como número de suas iterações a quantidade de vezes que o valor do *threshold* é ultrapassado e o segundo, a quantidade de canais. A cada índice da amostra da ultrapassagem do *threshold*, é descontado a quantidade de amostras (o desvio de atraso do filtro FIR), acrescentando seu número. Extraíndo o segmento, utilizando a abordagem de janelamento adjacente, são calculadas as características

de Média Absoluta do Sinal (MAV), a integral do sinal, a variância dos seus dados e o seu valor RMS, de todos os canais, as quais correspondem as equações de (10) a (13) na Tabela 1.



**Figura 47 – SubVI de segmentação e extração de características, sendo a) seu símbolo e b) seu diagrama de blocos.**  
**Fonte: Autoria própria.**

Para essa etapa, foram escolhidas as principais características do domínio do tempo pela sua facilidade de extração, alta capacidade de classificação e baixo custo computacional.

A saída de todos esses dados (já em formatos de *array*) é encaminhada para um outro *loop For*, que seleciona as características escolhidas pelo usuário para a gravação. Esse *loop* é responsável por agrupar em apenas um conjunto de dados as características que o usuário desejou no início do programa. Utilizando uma função de busca por meio de um bloco *Search 1D Array*, encontra-se quais são as características selecionadas e as insere utilizando o bloco *Array Subset*.

Os dados selecionados são acrescidos ao seu final da saída correspondente ao seu movimento. Um *array* contendo dois itens indicam a sequência [1,0] e [0,1] para a flexão e extensão, respectivamente. Finaliza-se assim a etapa de segmentação e extração de características.

A última etapa refere-se à escolha de novos arquivos para serem agrupados em um banco de dados para classificação e as configurações das gravações dos mesmos (Figura 44d). O usuário seleciona o próximo arquivo a ser lido pelo e aperta o botão para iniciar as sequências de processamento. Até o usuário selecionar o arquivo, o programa aguarda o seu comando em um *loop While*, contendo um indicador (led booleano) para o alertar. Quando se termina todo o procedimento, o usuário pode selecionar terminar de processá-los, selecionando o botão de parada.

Com isso, o programa salva os dados processados com o nome escolhido pelo usuário. Algumas informações são adicionadas na tela sobre a quantidade de dados processados e de amostras presentes neste arquivo salvo.



**APÊNDICE C - Código de implementação da MLP no MATLAB®**

```

%% Organizar_Dados
% Declaração das variáveis
IN=[CH1,CH2,CH3,CH4,CH5,CH6,CH7,CH8]; % Entrada
Out=[S1,S2]; % Saída
All=[IN,Out]; % Todos os dados juntos
% Mudança da posição dos dados
l=randperm(numel(All(:,1)));
NAll=ones(size(All));
for i=1:numel(All(:,1));
    NAll(i,:)=All(l(i),:);
end
% Seleção da quantidade de amostras para o conjunto de treinamento e
% validação
NAll;
fl=25;
ex=25;
a=1;
i=1;
j=1;
[b,c]=size(NAll);
% Seleção das amostras de flexão
while j<=fl;
    if NAll(i,c-1)==1;
        Test(j,:)=NAll(i,:);
        ii(j)=i;
        j=j+1;
    end
    i=i+1;
end
ii;
j=1;
i=1;
% Seleção das amostras de extensão
while j<=ex;
    if NAll(i,c)==1;
        Test(j+fl,:)=NAll(i,:);
        ii(j+fl)=i;
        j=j+1;
    end
    i=i+1;
end
% Separação final dos dados
NNA=NAll;
NNA([sort(ii)],:)=[];
Trein=NNA(:,1:c-2);
d=NNA(:,c-1:c);
Teste=Test(:,1:c-2);
d2=Test(:,c-1:c);

clc % Limpa toda a janela de comandos
% Para analisar o comportamento da topologia escolhida, todo o sistema é
% executado 30 vezes.
for ii=1:30
    [amostras1,n0]=size(Trein); % Carrega conjunto de treinamento
    x0=-1*ones(1,amostras1)'; % Cria variável para o limiar de ativação
    XTr=[x0,(Trein.*1000)]; % Conjunto total de treinamento
    n1=9; % Neurônios da camada escondida
    n2=2; % Neurônios da camada de saída
    W1=randn(n1,n0+1)/1; % Primeiro conjunto de pesos sinápticos
    W2=rand(n2,n1+1)/1; % Segundo conjunto de pesos sinápticos

```

```

n=1e-3; % Taxa de aprendizagem
epoca=1; % Início do contador de épocas
b1=0.5; % Inclinação da função tangente hiperbólica
b2=0.5; %Inclinação da função logistica
e=500e-8; % Precisão do erro quadrático médio
aux=1; % Variável auxiliar para parar o treinamento da rede
E=0; % Erro quadrático médio
E2=0; % Variável auxiliar para a construção de gráfico do erro
tic % Inicializador do contador de tempo
while aux==1;
    if epoca==1;
        % Passo Forward, demosntrado anteriormente
        I1=XTr*W1';
        Y1=tangentehip(b1,I1);
        Y1=[-1*ones(amostras1,1),Y1];
        I2=Y1*W2';
        Y2=Logistica(b2,I2);
        Eat=EQMG(d,Y2); % Erro quadrático médio
    end
    Ean=Eat; % Atualização do erro para cálculo da precisão
        % Passo Forward, demosntrado anteriormente
        I1=XTr*W1';
        Y1=tangentehip(b1,I1);
        Y1=[-1*ones(amostras1,1),Y1];
        I2=Y1*W2';
        Y2=Logistica(b2,I2);
        %Passo Backward do algoritmo backpropagation
        g11=dLogistica(b2,I2); % Derivada da função logistica
        delta2=(d-Y2).*g11;
        W2=W2+n*delta2'*Y1;
        g12=dtanghip(b1,I1); % Derivada da função tangente hiperbólica
        delta1=(W2(:,2:n1+1)'\*delta2')'\*g12;
        W1=W1+n*delta1'*XTr;
        %Passo Forward
        I1=XTr*W1';
        Y1=tangentehip(b1,I1);
        Y1=[-1*ones(amostras1,1),Y1];
        I2=Y1*W2';
        Y2=Logistica(b2,I2);
        Eat=EQMG(d,Y2);
        precisao=abs(Eat-Ean); % Cálculo da precisão
        E(epoca)=precisao; % Gravação dos erros pela época
        epoca=epoca+1; % Contador de época
        if epoca==10000 % Verificador se ultrapassou o número de épocas
            aux=0;
        end
        if precisao<=e % Verificador se a precisão atingiu o seu limite
            aux=0;
        end
    end
    % Fim do treinamento
    toc % Término da contagem de tempo
    Y2s=zeros(amostras1,n2);
    % Função para determinar o maior valor dos vetores
    % equivalente a saída, arredondando os valores para 0 e 1.
    for i=1:amostras1
        [v_max,indice]=max(Y2(i,:));
        Y2s(i,indice)=1;
    end
end
% Rotina para analisar a quantidade de acertos durante a etapa de
% treinamento.

```

```

l=0;
for i=1:amostras1
    PP(i,1)=isequal(Y2s(i,:),d(i,:));
    if PP(i,1)==0
        l=l+1;
    end
end
% Cálculo e apresentação da porcentagem de acertos do treinamento além do
% gráfico do erro
acertos=((amostras1-l)*100)/amostras1;
l;
epoca2=1:numel(E);
figure(1)
plot(epoca2,E,'LineWidth',2);
hold on
acertos_treinamento(ii)=acertos;

% Teste da Rede, etapa de validação
amostras2=numel(Teste(:,1));
x0a=-1*ones(1,amostras2)';
Rede_data1=[x0a,(Teste.*1000)];
% Etapa Forward
I1r=Rede_data1*W1';
Y1r=tangentehip(b1,I1r);
Y1r=[-1*ones(amostras2,1),Y1r];
I2r=Y1r*W2';
Y2r=Logistica(b2,I2r);
Y2b=zeros(amostras2,n2);
% Arredondamento dos valores para 0 e 1
for i=1:amostras2
    [v_max,indice]=max(Y2r(i,:));
    Y2b(i,indice)=1;
end
% Análise de acertos da rede na validação
l=0;
for i=1:amostras2
    P(i,1)=isequal(Y2b(i,:),d2(i,:));
    if P(i,1)==0
        l=l+1;
    end
end
% Quantidade de acertos da rede na validação
acertos=((amostras2-l)*100)/amostras2;
acertos_validacao(ii)=acertos;
end

hold off
acertos_treinamento
mean(acertos_treinamento)
acertos_validacao
mean(acertos_validacao)

```

---