

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE INFORMÁTICA
ESCOLA DE ENGENHARIA
CURSO DE ENGENHARIA DE COMPUTAÇÃO

INGRID FLESCH LOPES

**Caracterização dos sinais mioelétricos dos movimentos do segmento mão-
braço através de regressão logística**

Monografia apresentada como requisito parcial para a obtenção do grau de Bacharel em Engenharia de Computação.

Orientador: Prof. Dr. Alexandre Balbinot

Porto Alegre
2014

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitor: Prof. Carlos Alexandre Netto

Vice-Reitor: Prof. Rui Vicente Oppermann

Pró-Reitor de Graduação: Prof. Sérgio Roberto Kieling Franco

Diretor do Instituto de Informática: Prof. Luís da Cunha Lamb

Diretor da Escola de Engenharia: Luiz Carlos Silva Filho

Coordenador do Curso de Engenharia de Computação: Prof. Marcelo Götz

Coordenador do Curso de Engenharia Elétrica: Prof. Ramon Carlos Poisl

Bibliotecária-Chefe do Instituto de Informática: Beatriz Regina Bastos Haro

AGRADECIMENTOS

RESUMO

Os sinais mioelétricos têm sido extensivamente estudados nas aplicações de controle de próteses multifuncionais. As pesquisas de sistemas como este, com interface neuromuscular, apresentam diversos desafios que ainda limitam, devido a fatores experimentais, seu emprego como dispositivo de tecnologia assistiva. Neste estudo, é proposto um método para estimar movimentos do segmento mão-braço a partir da aquisição de sinais eletromiográficos. Os algoritmos analisados extraem características destes sinais e usam um método de regressão para prever ações. As estratégias foram projetadas com o objetivo de reproduzir ações complexas, com até três graus de liberdade, fornecendo um controle intuitivo aos usuários de prótese. Foram realizadas diversas configurações de teste, variando, por exemplo, o número de canais utilizados, as características do sinal e o layout das bases de teste e treinamento. Os melhores resultados revelaram uma taxa de acerto geral média entre os cinco voluntários de 95.1%. Um dos indivíduos se destacou por ter todos os 19 movimentos testados corretamente classificados, evidenciando, portanto, uma taxa de acerto de 100%. Este desempenho destaca, por conseguinte, o método de regressão logística como um bom classificador de sinais mioelétricos dos movimentos do segmento mão-braço.

Palavras-chave: Sinais mioelétricos. Regressão logística. Aprendizado de máquinas.

Characterization of myoelectric signals of movements of the arm using logistic regression

ABSTRACT

The myoelectric signals have been extensively studied in multifunctional prosthesis control applications. The studies on this kind of system, with neuromuscular interface, present several challenges that limit, due to experimental factors, their employment as assistive technology device. In this study, methods are proposed for estimating certain movements of a human arm from the acquisition of electromyographic signals. The analyzed algorithms extract features from this signals and use a regression technique to predict actions. The strategies aimed at reproducing complex actions, with three degrees of freedom, providing an intuitive control to the prosthesis users. Several test configurations were tested, ranging, for example, the number of channels considered, the signal characteristics and the test and training set layout. The best results revealed an average accuracy rate, of the five volunteers, of 95.1%. One of the individuals stood out for having all 19 movements tested correctly classified, thus showing an accuracy rate of 100%. This performance therefore highlights the logistic regression method as a good classifier for myoelectric signals from arm movements.

Keywords: Myoelectric signal. Logistic regression. Machine learning.

LISTA DE FIGURAS

FIGURA 1: NEURÔNIO.....	14
FIGURA 2: FASES DO POTENCIAL DE AÇÃO.....	17
FIGURA 3: ESTÍMULOS E RESPECTIVAS VARIAÇÕES DE TENSÃO NA MEMBRANA.....	18
FIGURA 4: JUNÇÃO NEUROMUSCULAR.....	20
FIGURA 5: PRINCIPAIS MÚSCULOS SUPERFICIAIS DO BRAÇO E ANTEBRAÇO.....	21
FIGURA 6: O POSICIONAMENTO IDEAL DO ELETRODO DE SUPERFÍCIE É ENTRE A UNIDADE MOTORA E A INSERÇÃO DE TENDÕES DO MÚSCULO.....	23
FIGURA 7: FUNÇÃO LOGÍSTICA.....	25
FIGURA 8: ESQUEMA DO SISTEMA EXPERIMENTAL DO PROJETO.....	29
FIGURA 9: ANIMAÇÃO DO MOVIMENTO COMPOSTO DE EXTENSÃO E FLEXÃO DO PUNHO.....	32
FIGURA 10: MOVIMENTOS SIMPLES: (A) REPOUSO, (B) EXTENSÃO DO PUNHO, (C) FLEXÃO DO ANTEBRAÇO, (D) FLEXÃO DO PUNHO, (E) CONTRAÇÃO DA MÃO E (F) ROTAÇÃO DO ANTEBRAÇO.....	33
FIGURA 11: MOVIMENTOS COMPOSTOS: (A) ROTAÇÃO DO ANTEBRAÇO COM FLEXÃO DO ANTEBRAÇO, (B) ROTAÇÃO DO ANTEBRAÇO COM CONTRAÇÃO DA MÃO, (C) EXTENSÃO SEGUIDA DE FLEXÃO DO PUNHO E, (D) CONTRAÇÃO DA MÃO E FLEXÃO DO ANTEBRAÇO.....	34
FIGURA 12: (A) SÉRIE 1, (B) SÉRIE 2 E (C) SÉRIE 3.....	36
FIGURA 13: ARQUIVO DE AQUISIÇÃO DE DADOS ".LVM".....	37
FIGURA 14: FLUXOGRAMA DO PROGRAMA DE AQUISIÇÃO.....	38
FIGURA 15: INTERFACE DO SISTEMA DE AQUISIÇÃO.....	39
FIGURA 16: ARQUIVO GERADO DURANTE A ETAPA DE CALIBRAÇÃO DOS CANAIS DO VOLUNTÁRIO 2.....	40

FIGURA 17: FLUXOGRAMA DO PROGRAMA DE CALIBRAÇÃO.....	40
FIGURA 18: INTERFACE DA ROTINA DE CALIBRAÇÃO.....	41
FIGURA 19: SINAL RETIFICADO.....	42
FIGURA 20: SINAL APÓS OPERAÇÃO DE OFFSET.....	43
FIGURA 21: SINAL NORMALIZADO.....	44
FIGURA 22: SINAL DO CANAL 1 ANTES E DEPOIS DA SEGMENTAÇÃO.....	45
FIGURA 24: ARQUIVO GERADO APÓS O BLOCO DE EXTRAÇÃO DE CARACTERÍSTICAS.....	48
FIGURA 25: EXEMPLO DE ARQUIVO DE TREINAMENTO CONTENDO TRÊS CANAIS E DUAS CARACTERÍSTICAS POR CANAL: RMS E DESVIO PADRÃO..	49
FIGURA 26: ENSAIO COM A VOLUNTÁRIA 5.....	51
FIGURA 27: POSICIONAMENTO DOS ELETRODOS DOS CANAIS 0, 1, 4 E 6..	52
FIGURA 29: RELAÇÃO ENTRE O AUMENTO DO PARÂMETRO REGULADOR E A DIMINUIÇÃO DA COMPLEXIDADE DO MODELO.....	54
FIGURA 31: CALIBRAÇÃO DO CANAL REFERENTE AO BÍCEPS BRAQUIAL.	58
FIGURA 32: RESULTADOS DO VOLUNTÁRIO 1 USANDO APENAS RMS PARA CARACTERIZAR OS SETE CANAIS DE AQUISIÇÃO.....	59
FIGURA 33: DESEMPENHO DO CLASSIFICADOR PARA DESCRIÇÃO DOS DADOS DO VOLUNTÁRIO 1 ATRAVÉS DE CADA CARACTERÍSTICA INDIVIDUALMENTE.....	60
FIGURA 34: RESULTADOS DO VOLUNTÁRIO 1 USANDO RMS, DESVIO PADRÃO, VARIÂNCIA E OBLIQUIDADE EM CONJUNTO PARA CARACTERIZAR OS SETE CANAIS DE AQUISIÇÃO.....	62
FIGURA 35: DESEMPENHO DO CLASSIFICADOR X CANAIS PARA O VOLUNTÁRIO 1.....	63
FIGURA 36: PARCELA DA BASE TOTAL UTILIZADA PARA O CONJUNTO DE TREINAMENTO X TAXA DE ACERTO GERAL PARA O VOLUNTÁRIO 1.....	64

FIGURA 37: CALIBRAÇÃO DO CANAL 0 REFERENTE AO BÍCEPS BRAQUIAL.....	66
FIGURA 39: DESEMPENHO DO CLASSIFICADOR PARA DESCRIÇÃO DOS DADOS DO VOLUNTÁRIO 2 ATRAVÉS DE CADA CARACTERÍSTICA INDIVIDUALMENTE.....	69
FIGURA 40: RESULTADOS DO VOLUNTÁRIO 2 USANDO RMS, DESVIO PADRÃO, VARIÂNCIA E OBLIQUIDADE EM CONJUNTO PARA CARACTERIZAR OS SETE CANAIS DE AQUISIÇÃO.....	69
FIGURA 41: DESEMPENHO DO CLASSIFICADOR X CANAIS PARA O VOLUNTÁRIO 2.....	70
FIGURA 42: DESEMPENHO DO CLASSIFICAR PARA A CARACTERIZAÇÃO DO SINAL ATRAVÉS DO VALOR RMS DE APENAS CINCO CANAIS DE AQUISIÇÃO DO VOLUNTÁRIO 2.....	71
FIGURA 43: PARCELA DA BASE TOTAL UTILIZADA PARA O CONJUNTO DE TREINAMENTO X TAXA DE ACERTO GERAL PARA O VOLUNTÁRIO 2.....	72
FIGURA 44: RESULTADOS DO VOLUNTÁRIO 3 USANDO APENAS RMS PARA CARACTERIZAR OS SETE CANAIS DE AQUISIÇÃO.....	75
FIGURA 45: DESEMPENHO DO CLASSIFICADOR PARA DESCRIÇÃO DOS DADOS DO VOLUNTÁRIO 3 ATRAVÉS DE CADA CARACTERÍSTICA INDIVIDUALMENTE.....	76
FIGURA 46: RESULTADOS DO VOLUNTÁRIO 3 USANDO RMS E DESVIO PADRÃO EM CONJUNTO PARA CARACTERIZAR OS SETE CANAIS DE AQUISIÇÃO.....	76
FIGURA 47: DESEMPENHO DO CLASSIFICADOR X CANAIS PARA O VOLUNTÁRIO 3.....	78
FIGURA 48: DESEMPENHO DO CLASSIFICAR PARA A CARACTERIZAÇÃO DO SINAL ATRAVÉS DO VALOR RMS DE APENAS CINCO CANAIS DE AQUISIÇÃO DO VOLUNTÁRIO 3.....	79
FIGURA 49: PARCELA DA BASE TOTAL UTILIZADA PARA O CONJUNTO DE TREINAMENTO X TAXA DE ACERTO GERAL.....	80
FIGURA 50: RESULTADOS DO VOLUNTÁRIO 3 COM CLASSIFICADOR MODELADO UTILIZANDO O CONJUNTO DE TREINAMENTO FORMADO POR APENAS 22.9% DA BASE COMPLETA DE OBSERVAÇÕES.....	82

FIGURA 51: CALIBRAÇÃO DO CANAL ZERO REFERENTE AO BÍCEPS BRAQUIAL DO VOLUNTÁRIO 4.....	83
FIGURA 52: RESULTADOS DO VOLUNTÁRIO 4 USANDO APENAS RMS PARA CARACTERIZAR OS SETE CANAIS DE AQUISIÇÃO.....	85
FIGURA 53: DESEMPENHO DO CLASSIFICADOR PARA DESCRIÇÃO DOS DADOS DO VOLUNTÁRIO 4 ATRAVÉS DE CADA CARACTERÍSTICA INDIVIDUALMENTE.....	85
FIGURA 54: RESULTADOS DO VOLUNTÁRIO 4 USANDO OBLIQUIDADE PARA CARACTERIZAR OS SETE CANAIS DE AQUISIÇÃO.....	86
FIGURA 55: DESEMPENHO DO CLASSIFICADOR X CANAIS PARA O VOLUNTÁRIO 4.....	87
FIGURA 56: RESULTADOS DO VOLUNTÁRIO 4 USANDO RMS PARA CARACTERIZAR TRÊS CANAIS.....	87
FIGURA 57: PARCELA DA BASE TOTAL UTILIZADA PARA O CONJUNTO DE TREINAMENTO X TAXA DE ACERTO GERAL.....	88
FIGURA 58: CALIBRAÇÃO DO CANAL ZERO REFERENTE AO BÍCEPS BRAQUIAL DO VOLUNTÁRIO 5.....	90
FIGURA 59: RESULTADOS DO VOLUNTÁRIO 5 USANDO APENAS RMS PARA CARACTERIZAR OS SETE CANAIS DE AQUISIÇÃO.....	91
FIGURA 60: DESEMPENHO DO CLASSIFICADOR PARA DESCRIÇÃO DOS DADOS DO VOLUNTÁRIO 5 ATRAVÉS DE CADA CARACTERÍSTICA INDIVIDUALMENTE.....	92
FIGURA 61: RESULTADOS DO VOLUNTÁRIO 5 USANDO RMS, DESVIO PADRÃO, VARIÂNCIA E OBLIQUIDADE EM CONJUNTO PARA CARACTERIZAR OS SETE CANAIS DE AQUISIÇÃO.....	94
FIGURA 62: DESEMPENHO DO CLASSIFICADOR X CANAIS PARA O VOLUNTÁRIO 5.....	95
FIGURA 63: DESEMPENHO DO CLASSIFICAR PARA A CARACTERIZAÇÃO DO SINAL ATRAVÉS DO VALOR RMS DE APENAS CINCO CANAIS DE AQUISIÇÃO DO VOLUNTÁRIO 5.....	96
FIGURA 64: PARCELA DA BASE TOTAL UTILIZADA PARA O CONJUNTO DE TREINAMENTO X TAXA DE ACERTO GERAL.....	97

FIGURA 65: RESULTADOS DO VOLUNTÁRIO 5 USANDO APENAS RMS PARA CARACTERIZAR OS SETE CANAIS DE AQUISIÇÃO.....	99
FIGURA 66: DESEMPENHO DO CLASSIFICADOR PARA DESCRIÇÃO DOS DADOS DO VOLUNTÁRIO 5 ATRAVÉS DE CADA CARACTERÍSTICA INDIVIDUALMENTE.....	100
FIGURA 67: DESEMPENHO DO CLASSIFICADOR X CANAIS PARA O VOLUNTÁRIO 5.....	101
FIGURA 68: DESEMPENHO DO CLASSIFICAR PARA A CARACTERIZAÇÃO DO SINAL ATRAVÉS DO VALOR RMS DE APENAS SEIS CANAIS DE AQUISIÇÃO.....	102
FIGURA 69: CALIBRAÇÃO: A) CANAL 1, B) CANAL 2, C) CANAL 3, D) CANAL 4, E) CANAL 5, F) CANAL 7 E G) CANAL 8.....	110
FIGURA 70: CALIBRAÇÃO: A) CANAL 1, B) CANAL 2, C) CANAL 3, D) CANAL 4, E) CANAL 5, F) CANAL 7 E G) CANAL 8.....	111
FIGURA 71: CALIBRAÇÃO: A) CANAL 1, B) CANAL 2, C) CANAL 3, D) CANAL 4, E) CANAL 5, F) CANAL 7 E G) CANAL 8.....	112
FIGURA 72: CALIBRAÇÃO: A) CANAL 1, B) CANAL 2, C) CANAL 3, D) CANAL 4, E) CANAL 5, F) CANAL 7 E G) CANAL 8.....	113

LISTA DE TABELAS

TABELA 1: MÚSCULOS SUPERFICIAIS DO SEGMENTO MÃO-BRAÇO E SUAS FUNÇÕES.....	21
TABELA 2: MOVIMENTOS DE ATIVAÇÃO DOS MÚSCULOS ESCOLHIDOS PARA CARACTERIZAR OS MOVIMENTOS.....	30
TABELA 3: MÚSCULOS SUPERFICIAIS DO SEGMENTO MÃO-BRAÇO E MOVIMENTOS SELECIONADOS QUE OS ATIVAM.....	33
TABELA 4: SÉRIE DE MOVIMENTOS.....	35
TABELA 5: ASSOCIAÇÃO DE CANAIS E MÚSCULOS.....	51
TABELA 6: MOVIMENTOS REALIZADOS PELO VOLUNTÁRIO 1.....	57
TABELA 7: DISTRIBUIÇÃO DOS MOVIMENTOS QUE FORMAM A BASE DE DADOS DE TESTE USADOS NA SEÇÃO 4.1.1.....	58
TABELA 8: TAXA DE ACERTO PARA MELHOR ESCOLHA DE PARÂMETRO REGULADOR DO MODELO.....	59
TABELA 9: MATRIZ DE DECISÃO DO CLASSIFICADOR FRENTE A CADA CATEGORIA DE MOVIMENTO.....	60
TABELA 10: TAXA DE ACERTO DOS MOVIMENTOS E TAXA DE ACERTO GERAL.....	61
TABELA 11: MATRIZ DE DECISÃO DO CLASSIFICADOR FRENTE A CADA CATEGORIA DE MOVIMENTO.....	61
TABELA 12: TAXA DE ACERTO DOS MOVIMENTOS E TAXA DE ACERTO GERAL.....	63
TABELA 13: MATRIZ DE DECISÃO DO CLASSIFICADOR FRENTE A CADA CATEGORIA DE MOVIMENTO.....	63
TABELA 14: DETALHAMENTO DOS CASOS DE TESTE VARIANDO AS DIMENSÕES DO CONJUNTO DE DADOS DE TESTE E TREINAMENTO.....	65
TABELA 15: DISTRIBUIÇÃO DOS MOVIMENTOS REALIZADOS PELO VOLUNTÁRIO 2 DURANTE O ENSAIO.....	65

TABELA 16: DISTRIBUIÇÃO DOS MOVIMENTOS QUE FORMAM A BASE DE DADOS DE TESTE USADOS NA SEÇÃO 4.2.1.....	66
TABELA 17: TAXA DE ACERTO DOS MOVIMENTOS E TAXA DE ACERTO GERAL.....	67
TABELA 18: MATRIZ DE DECISÃO DO CLASSIFICADOR FRENTE A CADA CATEGORIA DE MOVIMENTO.....	67
TABELA 19: TAXA DE ACERTO DOS MOVIMENTOS PARA AS BASES DE TREINAMENTO FORMADAS POR 62.96 E 73.1% DO CONJUNTO TOTAL DE OBSERVAÇÕES.....	72
TABELA 20: DISTRIBUIÇÃO DOS MOVIMENTOS REALIZADOS PELO VOLUNTÁRIO 3.....	73
TABELA 21: DISTRIBUIÇÃO DOS MOVIMENTOS QUE FORMAM A BASE DE DADOS DE TESTE USADOS NA SEÇÃO 4.3.1.....	73
TABELA 22: TAXA DE ACERTO DOS MOVIMENTOS E TAXA DE ACERTO GERAL.....	74
TABELA 23: MATRIZ DE DECISÃO DO CLASSIFICADOR FRENTE A CADA CATEGORIA DE MOVIMENTO.....	74
TABELA 24: TAXA DE ACERTO DOS MOVIMENTOS E TAXA DE ACERTO GERAL.....	77
TABELA 25: MATRIZ DE DECISÃO DO CLASSIFICADOR FRENTE A CADA CATEGORIA DE MOVIMENTO.....	77
TABELA 26: TAXA DE ACERTO DOS MOVIMENTOS E TAXA DE ACERTO GERAL.....	78
TABELA 27: MATRIZ DE DECISÃO DO CLASSIFICADOR FRENTE A CADA CATEGORIA DE MOVIMENTO.....	79
TABELA 28: DISTRIBUIÇÃO DOS MOVIMENTOS DA BASE DE TESTE.....	80
TABELA 29: TAXA DE ACERTO DOS MOVIMENTOS E TAXA DE ACERTO GERAL.....	81
TABELA 30: MATRIZ DE DECISÃO DO CLASSIFICADOR FRENTE A CADA CATEGORIA DE MOVIMENTO.....	81

TABELA 31: MOVIMENTOS REALIZADOS PELO VOLUNTÁRIO 4 DURANTE O ENSAIO.....	82
TABELA 32: DISTRIBUIÇÃO DOS MOVIMENTOS QUE FORMAM A BASE DE DADOS DE TESTE USADO NA SEÇÃO 4.4.1.....	84
TABELA 33: TAXA DE ACERTO DOS MOVIMENTOS E TAXA DE ACERTO GERAL.....	84
TABELA 34: MATRIZ DE DECISÃO DO CLASSIFICADOR FRENTE A CADA CATEGORIA DE MOVIMENTO.....	84
TABELA 35: TAXA DE ACERTO DOS MOVIMENTOS E TAXA DE ACERTO GERAL.....	87
TABELA 36: MOVIMENTOS REALIZADOS PELO VOLUNTÁRIO 5 DURANTE O ENSAIO.....	89
TABELA 37: DISTRIBUIÇÃO DOS MOVIMENTOS QUE FORMAM A BASE DE DADOS DE TESTE USADO NA SEÇÃO 4.5.1.....	90
TABELA 38: TAXA DE ACERTO DOS MOVIMENTOS E TAXA DE ACERTO GERAL.....	91
TABELA 39: MATRIZ DE DECISÃO DO CLASSIFICADOR FRENTE A CADA CATEGORIA DE MOVIMENTO.....	91
TABELA 40: TAXA DE ACERTO DOS MOVIMENTOS E TAXA DE ACERTO GERAL.....	93
TABELA 41: MATRIZ DE DECISÃO DO CLASSIFICADOR FRENTE A CADA CATEGORIA DE MOVIMENTO.....	93
TABELA 42: TAXA DE ACERTO DOS MOVIMENTOS E TAXA DE ACERTO GERAL.....	94
TABELA 43: MATRIZ DE DECISÃO DO CLASSIFICADOR FRENTE A CADA CATEGORIA DE MOVIMENTO.....	95
TABELA 44: MOVIMENTOS REALIZADOS PELOS CINCO VOLUNTÁRIOS..	97
TABELA 45: DISTRIBUIÇÃO DOS MOVIMENTOS QUE FORMAM A BASE DE DADOS DE TESTE USADO NA SEÇÃO 4.6.1.....	98
.....	99

TABELA 46: TAXA DE ACERTO DOS MOVIMENTOS E TAXA DE ACERTO GERAL.....[99](#)

TABELA 47: MATRIZ DE DECISÃO DO CLASSIFICADOR FRENTE A CADA CATEGORIA DE MOVIMENTO.....[100](#)

TABELA 48: TAXA DE ACERTO DOS MOVIMENTOS E TAXA DE ACERTO GERAL.....[101](#)

TABELA 49: MATRIZ DE DECISÃO DO CLASSIFICADOR FRENTE A CADA CATEGORIA DE MOVIMENTO.....[102](#)

LISTA DE ABREVIATURAS E SIGLAS

EMG	Sinais Eletromiográficos
ACh	Acetilcolina
VI	<i>Virtual Instruments</i>
SVM	<i>Support Vector Machine</i>
CVM	Contração Voluntária Máxima
SNR	<i>Signal Noise Ratio</i>
MUAP	<i>Motor Unit Action Potential</i>
RMS	<i>Root Mean Square</i>
RA	Rotação do Antebraço
FA	Flexão do Antebraço
CM	Contração da Mão
FP	Flexão do Punho
EP	Extensão do Punho
RAF	Rotação e Flexão do Antebraço
RAC	Rotação do Antebraço e Contração da Mão
CMF	Contração da Mão e Flexão do Antebraço
EFP	Extensão e Flexão do Punho

SUMÁRIO

1 INTRODUÇÃO.....	<u>10</u>
1.1 Justificativa.....	<u>10</u>
1.2 Objetivos.....	<u>10</u>
2 REVISÃO BIBLIOGRÁFICA.....	<u>12</u>
2.1 Sinal Mioelétrico.....	<u>12</u>
2.2 Sistema Nervoso.....	<u>13</u>
2.2.1 Células Excitáveis.....	<u>13</u>
2.2.2 Neurônios.....	<u>14</u>
2.3 Potencial de Ação.....	<u>14</u>
2.3.1 Gradiente Eletroquímico.....	<u>15</u>
2.3.2 Canais Iônicos.....	<u>15</u>
2.3.3 Potencial de Repouso.....	<u>16</u>
2.3.4 Geração do Potencial de Ação.....	<u>17</u>
2.4 Fibras Musculares.....	<u>18</u>
2.4.1 Contração Muscular.....	<u>19</u>
2.4.2 Junção Neuromuscular.....	<u>19</u>
2.4.3 Unidades Motoras.....	<u>20</u>
2.4.4 Músculos e Movimentos do Braço.....	<u>20</u>
2.5 Captura do Sinal EMG.....	<u>22</u>
2.5.1 Eletrodos de Superfície.....	<u>22</u>
2.5.2 Posicionamento dos Eletrodos.....	<u>22</u>
2.6 Regressão Logística.....	<u>23</u>
2.6.1 Função Preditora.....	<u>24</u>
2.6.2 Função Logística.....	<u>24</u>
2.6.3 Probabilidade.....	<u>25</u>
2.6.4 Estimação dos Parâmetros.....	<u>27</u>
3 METODOLOGIA EXPERIMENTAL.....	<u>29</u>
3.1 Plataforma de hardware.....	<u>30</u>
3.1.1 Eletromiógrafo.....	<u>30</u>
3.1.2 Sistema de aquisição de dados.....	<u>30</u>
3.2 Plataforma de software.....	<u>31</u>
3.2.1 Modelo Virtual.....	<u>31</u>
3.2.1.1 Movimentos.....	<u>32</u>
3.2.1.2 Séries.....	<u>34</u>
3.2.2 Procedimento para aquisição dos dados.....	<u>36</u>
3.2.3 Procedimento de calibração.....	<u>39</u>
3.3 Pré-processamento do sinal mioelétrico.....	<u>41</u>
3.3.1 Retificação de Onda Completa.....	<u>41</u>
3.3.2 Remoção do offset.....	<u>42</u>
3.3.3 Filtragem.....	<u>43</u>

3.3.3 Normalização.....	44
3.3.4 Segmentação.....	45
3.3.5 Extração de Características.....	47
3.4 Processamento do sinal mioelétrico.....	48
3.4.1 Modelo de Regressão.....	49
3.4.3 Treinamento.....	50
3.5 Ensaios e Indivíduos.....	50
3.5.1 Posicionamento dos Eletrodos.....	51
3.5.2 Testes e Resultados.....	53
3.5.2.1 Taxa de acerto.....	53
3.5.2.2 Parâmetro regulador.....	54
3.5.2.3 Casos de teste.....	55
4 RESULTADOS E DISCUSSÕES.....	57
4.1 Voluntário 1.....	57
4.1.1 Variação de características utilizadas.....	58
4.1.1.1 RMS.....	58
4.1.1.2 RMS, desvio padrão, variância e obliquidade.....	60
4.1.2 Variação do número de canais utilizados.....	62
4.1.3 Variação do tamanho do conjunto de treinamento.....	64
4.2 Voluntário 2.....	65
4.2.1 Variação de características utilizadas.....	66
4.2.1.1 RMS.....	67
4.2.1.2 RMS, Desvio Padrão, Variância e Obliquidade.....	68
4.2.2 Variação do número de canais utilizados.....	69
4.2.3 Variação do tamanho do conjunto de treinamento.....	71
4.3 Voluntário 3.....	73
4.3.1 Variação de características utilizadas.....	73
4.3.1.1 RMS.....	74
4.3.1.2 RMS e Desvio Padrão.....	75
4.3.2 Variação do número de canais utilizados.....	77
4.3.3 Variação do tamanho do conjunto de treinamento.....	79
4.4 Voluntário 4.....	82
4.4.1 Variação de características utilizadas.....	83
4.4.1.1 RMS.....	84
4.4.1.2 Obliquidade.....	85
4.4.2 Variação do número de canais utilizados.....	86
4.4.3 Variação do tamanho do conjunto de treinamento.....	88
4.5 Voluntário 5.....	89
4.5.1 Variação das características utilizadas.....	90
4.5.1.1 RMS.....	90
4.5.1.2 RMS, desvio padrão, variância e obliquidade.....	92
4.5.2 Variação do número de canais utilizados.....	94
4.5.3 Variação do tamanho do conjunto de treinamento.....	96
4.6 Todos voluntários.....	97
4.6.1 Variação das características utilizadas.....	98
4.6.1.1 RMS.....	98
4.6.1.2 RMS, desvio padrão e variância.....	100
4.6.2 Variação do número de canais utilizados.....	101

5 CONCLUSÃO.....	103
REFERÊNCIAS.....	104
APÊNDICE – LABVIEW: AQUISIÇÃO.....	107
APÊNDICE – LABVIEW: CALIBRAÇÃO.....	108
APÊNDICE – CALIBRAÇÃO DO VOLUNTÁRIO 1.....	110
APÊNDICE – CALIBRAÇÃO DO VOLUNTÁRIO 2.....	111
APÊNDICE – CALIBRAÇÃO DO VOLUNTÁRIO 4.....	112
APÊNDICE – CALIBRAÇÃO DO VOLUNTÁRIO 5.....	113

1 INTRODUÇÃO

A deficiência física ou deficiência motora é uma limitação do funcionamento físico-motor do corpo. A engenharia de reabilitação é o ramo da engenharia responsável por projetar, desenvolver e aplicar soluções tecnológicas para os problemas enfrentados por indivíduos portadores de alguma deficiência, promovendo, desta forma, a integração à sociedade, autonomia e independência (TAUB *et al.*, 1999).

A prótese, um exemplo de tecnologia assistiva, intervem como substituto funcional para membros amputados, congenitamente malformados ou ausentes que tem como objetivo conquistar a mobilidade de seus usuários (TAUB *et al.*, 1999).

1.1 Justificativa

Dada a funcionalidade das próteses, a principal exigência durante a sua elaboração é a praticidade de utilização (HAHNE *et al.*, 2014), (KENT, *et al.*, 2014), (LIN & KULIC, 2014). A eletromiografia tem sido estudada como fonte de gerenciamento de dispositivos como, por exemplo, cadeiras de roda, braços robóticos e próteses mioelétricas, pois carrega informações neurais do movimento. Este método é comumente referenciado por controle mioelétrico. Diversas pesquisas têm-se concentrado em algoritmos de reconhecimento de padrões dos sinais eletromiográficos (EMG) com o objetivo de fornecer melhorias nesta área (BUNDERSON, 2014), (JIANG *et al.*, 2012), (JIANG *et al.*, 2013), (PERSONNIER *et al.*, 2010), (DE LUCA *et al.*, 2010).

O grande paradigma deste método é a diferença entre os comportamentos de controle fornecido pelo reconhecimento de padrões e pelo sinal neuromuscular. Ocasionalmente, portanto, um contraste entre o estado da arte acadêmico e industrial. A classificação, baseada nos padrões reconhecidos nos movimentos, fornece um controle discreto do músculo. Já o controle real, neuromuscular, é um controle proporcional e simultâneo de múltiplos músculos (BUNDERSON, 2014), (JIANG *et al.*, 2013).

1.2 Objetivos

Este estudo visa a aplicação do método de regressão logística para o controle mioelétrico de certos movimentos do segmento mão-braço. Para uma aplicação clínica, o método deve exigir pouco treinamento do usuário, ser computacionalmente eficiente e,

também, ter bom desempenho com o menor número possível de eletrodos. Estes aspectos são tratados com a redução da quantidade de dados de formação e número de canais utilizados no eletromiógrafo.

A fim de compreender todos os elementos envolvidos no cumprimento desta premissa, primeiramente, será apresentado um estudo da anatomia e fisiologia do corpo que influenciam na produção destes sinais. É importante ressaltar que estudos nas áreas de instrumentação biomédica e de processamento de biosinais requerem um sólido conhecimento e, portanto, a revisão bibliográfica é essencial para o êxito deste trabalho.

2 REVISÃO BIBLIOGRÁFICA

2.1 Sinal Mioelétrico

A eletromiografia trata da detecção, análise e utilização de sinais elétricos advindos dos músculos esqueléticos. O sinal elétrico, gerado durante a ativação muscular, conhecido por sinal mioelétrico, é consequência das correntes elétricas geradas pela troca de íons através das membranas das células musculares e detectado com a ajuda dos eletrodos. Este sinal é afetado pelas propriedades anatômicas e fisiológicas do músculo, pelo controle do sistema nervoso, assim como pela instrumentação utilizada para detectá-lo e observá-lo (HAHNE *et al.*, 2014).

A movimentação do corpo humano é uma integração perfeita do cérebro, sistema nervoso e músculos. Quando um músculo é recrutado para realizar alguma atividade, o cérebro envia um estímulo, gerado pelo sistema nervoso central e encaminhado através dos neurônios, até o músculo alvo (OUTTEN *et al.*, 1996). Os músculos são enervados em grupos chamados unidades motoras. Estes grupos representam o ponto de junção entre o neurônio motor e a fibra muscular. Quando uma unidade motora é ativada, um correspondente potencial de ação muscular é produzido. A ativação a partir do sistema nervoso central se repete continuamente enquanto a geração de força muscular for requisitada. Estas ativações contínuas produzem trens de potenciais de ação musculares nas unidades motoras (MUAP). A superposição destes sinais de ativação de unidades motoras concorrentes são responsáveis por produzir o sinal EMG resultante (OUTTEN *et al.*, 1996).

De forma geral, sempre que é necessário gerar uma força maior, o estímulo aumenta e, portanto, mais unidades motoras são ativadas e a taxa de disparo das unidades motoras aumenta, resultando na expansão da amplitude do sinal EMG (OUTTEN *et al.*, 1996). A amplitude do sinal EMG está entre 1 e 10 mV, classificado portanto, como um sinal bastante fraco. Ele encontra-se na gama de frequências de 0-500 Hz e, a maior parte da energia se localiza na faixa de 50-150 Hz (DE LUCA, 2002). A fim de compreender o fenômeno da contração muscular é apresentado a seguir, a descrição do funcionamento das principais estruturas relacionadas ao movimento do segmento mão-braço.

2.2 Sistema Nervoso

O sistema nervoso é a rede de comunicação e controle do corpo. Para os seres humanos, este sistema tem funções sensoriais, integrativas e motoras. Esta última gera respostas, como a movimentação dos músculos, a estímulos e por isso, é objeto de estudo deste artigo (TORTORA, 2000). O sistema nervoso é o mais complexo dos onze sistemas do corpo humano, sendo composto por bilhões de neurônios e neuróglia e organizado em duas subcategorias principais: o sistema nervoso central que engloba o cérebro e medula espinhal, os agentes controladores; e o sistema nervoso periférico que inclui todos os outros elementos conectados do cérebro e medula espinhal aos músculos e glândulas, os agentes controlados (TORTORA, 2000).

O sistema nervoso periférico é dividido em duas categorias: o sistema nervoso somático e o sistema nervoso autônomo. Sendo o primeiro responsável pelos movimentos musculares focados neste estudo. O sistema nervoso somático é composto por neurônios sensoriais e por neurônios motores, responsáveis por conduzir impulsos originados no sistema nervoso central para os músculos esqueléticos. Pelo fato destas respostas motoras serem controláveis, é dito que esta parte do sistema é voluntária (TORTORA, 2000).

2.2.1 Células Excitáveis


Os neurônios e fibras musculares são consideradas células excitáveis por exibirem a propriedade de excitabilidade elétrica. Esta propriedade representa a habilidade das células de responderem a certos estímulos produzindo sinais elétricos como os potenciais de ação (BORON & BOULPAEP, 2003).

Esta classe de sinal pode se propagar pela membrana plasmática de um neurônio ou fibra muscular graças a presença de tipos específicos de canais iônicos operados por tensão. Quando um potencial de ação se forma no neurônio, ele libera uma substância química chamada neurotransmissor, que permitirá a comunicação com outros neurônios ou fibras musculares. Quando o potencial de ação atinge uma fibra muscular ele provoca sua contração, resultando em atividades como o movimento de membros do corpo (BORON & BOULPAEP, 2003).

2.2.2 Neurônios

A maioria dos neurônios são compostos por quatro partes: corpo celular, dendritos, zona de disparo e axônio. O corpo celular contém um núcleo envolto no citoplasma, composto por diversas organelas celulares. Os dendritos são prolongamentos dos neurônios que atuam na recepção dos estímulos nervosos e na transmissão deles para o corpo celular. O axônio é a seção do neurônio responsável por conduzir os impulsos elétricos até uma fibra muscular ou outro neurônio. A zona de disparo é onde as correntes elétricas atravessam a membrana celular atingindo o meio extracelular e, portanto, aplicando uma diferença de potencial na membrana que pode causar o início de um potencial de ação (BORON & BOULPAEP, 2003).

Figura 1: Neurônio.



Fonte: Adaptado de (TORTORA, 2000).

Os neurônios que estimulam as contrações dos músculos esqueléticos são os neurônios motores somáticos. Cada um destes neurônios tem um axônio filiforme, que se estende do cérebro ou medula espinal a um grupo de fibras do músculo esquelético, atingido graças às diversas ramificações do axônio. Os neurônios desta classe conduzem o potencial de ação a partir do sistema nervoso central até os órgão efetores, neste caso os músculos, através de nervos cranianos ou espinais (BORON & BOULPAEP, 2003).

2.3 Potencial de Ação

Os neurônios, assim como as células musculares, comunicam-se entre si através de duas classes de sinais elétricos, existentes graças à propriedade intrínseca de excitabilidade

elétrica destas células. A primeira classe, chamada potencial gradual, só pode funcionar em comunicações de distâncias curtas e não será descrita neste estudo. Já a classe chamada potencial de ação permite a comunicação com distâncias mais longas. A produção de ambos os sinais depende de duas características da membrana plasmática das células excitáveis: a presença de tipos específicos de canais iônicos e a existência de um potencial de repouso da membrana (BORON & BOULPAEP, 2003).

2.3.1 Gradiente Eletroquímico

A característica de permeabilidade seletiva da membrana plasmática permite que a célula mantenha diferentes concentrações de certas substâncias em ambos os lados da membrana. Um gradiente de concentração é a diferença na concentração de substâncias químicas de um lugar para o outro, tal como no interior e exterior da membrana. Um exemplo são os íons de sódio Na^+ que são encontrados em maior quantidade no fluido extracelular do que no citosol, meio intracelular. O oposto é verdade para os íons de potássio K^+ (TORTORA, 2000).

A membrana plasmática também pode criar uma diferença na distribuição dos íons, carregados positivamente e negativamente, entre os dois lados da membrana. Comumente, a superfície interna da membrana é carregada negativamente e, a superfície externa é carregada positivamente. A diferença de cargas entre estas duas regiões constitui o gradiente elétrico, conhecido por potencial da membrana (TORTORA, 2000).

A presença destes dois gradientes é crucial para mover substâncias através da membrana no sentido dos seus gradientes. Isto quer dizer que a substância migrará das maiores concentrações para as menores. E, similarmente, uma substância positivamente carregada tenderá à mover-se em direção a áreas carregadas negativamente; e uma substância negativamente carregada tenderá à mover-se em direção a áreas carregadas positivamente. A combinação de influências dos gradientes de concentração e elétrico no movimento de íons é referida como gradiente eletroquímico (TORTORA, 2000).

2.3.2 Canais Iônicos

A abertura de um canal iônico determina a passagem de íons através da membrana plasmática no sentido do gradiente eletroquímico. Os potenciais de ação neurais e musculares contam com dois tipos principais de canais iônicos (TORTORA, 2000):

- canais operados por tensão: as comportas deste canal abrem e fecham em resposta a uma mudança no potencial da membrana. Estes canais participam da geração e condução dos potenciais de ação nos axônios de todos os tipos de neurônios (TORTORA, 2000);
- canais constitutivamente ativos: as comportas deste canal abrem e fecham randomicamente. Estes canais são encontrados em quase todas as células e, são responsáveis, principalmente, pela existência do potencial de repouso da membrana (TORTORA, 2000).

2.3.3 Potencial de Repouso

O potencial de repouso da membrana existe devido a um pequeno acúmulo de íons negativos no citosol ao longo do interior da membrana, e uma acumulação equivalente de íons positivos no fluido extracelular ao longo da superfície externa da membrana (DE LUCA, 2007). Esta separação de cargas positivas e negativas representa a energia potencial, a qual é medida em milivolts (mV). Por conseguinte, quanto maior a diferença entre o acúmulo destas cargas, maior será o seu potencial. Em neurônios, o potencial de repouso varia de -40 mV à -90 mV, sendo o valor típico -70 mV (TORTORA, 2000).

Uma célula é dita polarizada quando exhibe uma tensão na membrana, este valor pode variar de -100 mV à +5 mV para diferentes tipos de células. O potencial de repouso da membrana é resultante de três fatores principais (TORTORA, 2000):

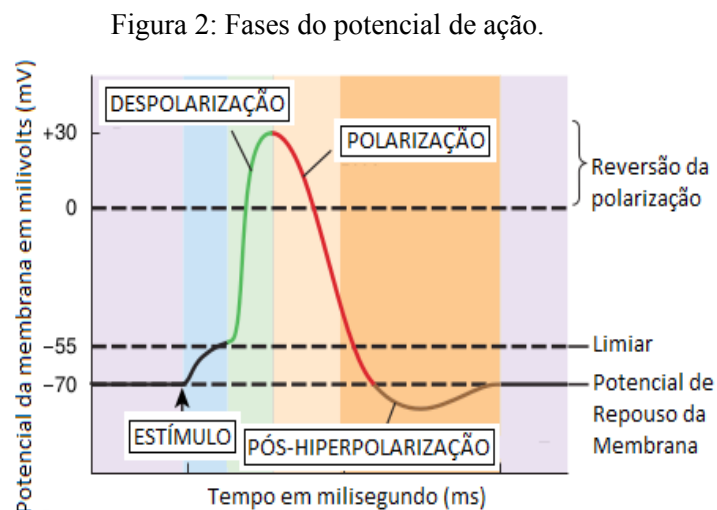
- distribuição desigual dos íons: como a membrana plasmática, tipicamente, possui mais canais de potássio do que de sódio, a quantidade de íons K^+ que migram em direção ao gradiente de concentração, saindo da célula e indo para o fluido extracelular, é maior que a quantidade de íons Na^+ que migram no sentido contrário. A medida que os cations K^+ saem, o interior da membrana torna-se mais negativa e o exterior torna-se mais positiva, contribuindo para a formação do potencial de repouso da membrana (TORTORA, 2000);
- incapacidade da maioria dos ânions de sair da célula: pelo fato de a maioria dos ânions contidos dentro das células estarem ligados às moléculas não difusíveis, eles não são livre para sair (TORTORA, 2000);
- bombas de sódio e potássio: o transporte ativo de íons de potássio e sódio para dentro e para fora da célula, respectivamente, é feito por diversas bombas de sódio e potássio distribuídas pela membrana celular. Essa ação estabelece uma maior concentração de sódio no meio extracelular e uma maior concentração de potássio no meio intracelular,

contribuindo, sensivelmente, portanto, para a manutenção do potencial de membrana (TORTORA, 2000).

2.3.4 Geração do Potencial de Ação

Na ausência de perturbações externas, o potencial da membrana permanece constante. Um potencial de ação, também conhecido por impulso nervoso, é uma sequência de eventos que ocorre rapidamente diminuindo e aumentando o potencial da membrana e, eventualmente, retornando ao estado de repouso. As principais fases deste fenômeno, ilustradas na Figura 2, são diferenciadas pela abertura e fechamento de comportas de dois tipos de canais iônicos operados por tensão. Durante a fase de repouso os canais de sódio e potássio operados por tensão estão inativos e a membrana plasmática se encontra, portanto, no potencial de repouso (DE LUCA, 2007).

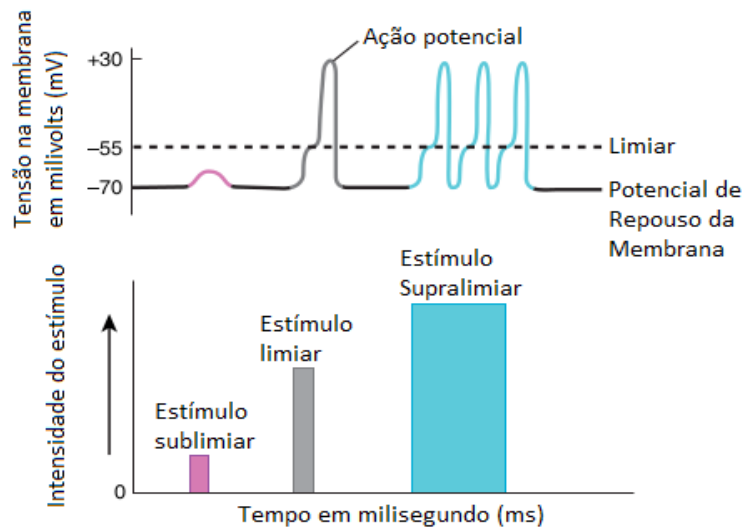
O primeiro canal a abrir as comportas, o canal de sódio operado por tensão, permite que os íons Na^+ entrem na célula, gerando o acúmulo de cargas positivas no interior da célula, causando portanto, a fase de despolarização. Ulteriormente, este canal de sódio é desativado e o canal de potássio operado por tensão permite que os íons K^+ fluam para fora da célula, gerando o acúmulo de cargas negativas no interior da célula, causando portanto, a fase de repolarização. A fase de pós-hiperpolarização ocorre quando as comportas deste canal de potássio permanecem abertas mesmo após o fim da fase de repolarização (DE LUCA, 2007).



Fonte: Adaptado de (TORTORA, 2000).

O potencial de ação é iniciado quando a despolarização atinge um limiar de tensão, por volta de -55 mV (Figura 3). Uma vez que este limiar é atingido, a amplitude do sinal de potencial de ação é sempre o mesmo, independentemente da intensidade do estímulo. Entretanto, quanto maior for a intensidade do estímulo maior será a frequência do sinal do potencial de ação (Figura 3). Os estímulos pertencentes a esta classe são chamados de supralimiaries. As respostas provenientes deste tipo de estímulo são mais intensas pelo fato desse estímulo ser capaz de despolarizar um maior número de fibras nervosas do que o estímulo limiar (DE LUCA, 2007).

Figura 3: Estímulos e respectivas variações de tensão na membrana.



Fonte: Adaptado de (TORTORA, 2000).

2.4 Fibras Musculares

Cada músculo esquelético é formado por milhares de células chamadas fibras ou células musculares. As principais propriedades intrínsecas dessas células, responsáveis pela contração muscular, são a excitabilidade, a habilidade de gerar potenciais de ação a partir de estímulos; e a contratilidade, a habilidade de contração quando estimulada por um potencial de ação (OUTTEN *et al.*, 1996).

Os neurônios motores somáticos são responsáveis por estimular as contrações dos músculos esqueléticos. Cada um destes neurônios tem um axônio filiforme, que se estende do cérebro ou medula espinal a um grupo de fibras do músculo esquelético, atingido graças às diversas ramificações do axônio (TORTORA, 2000).

2.4.1 Contração Muscular

O termo acoplamento excitação-contração é utilizado para descrever o processo de conversão de um estímulo elétrico em uma resposta mecânica. Tipicamente, o estímulo elétrico é representado pelo potencial elétrico e, a resposta mecânica representa a contração muscular (TORTORA, 2000).

A grosso modo, a despolarização da membrana, resultante do disparo de um potencial de ação, provoca o aumento da concentração de íons Ca^{2+} , graças a abertura do canal iônico associado. Este aumento ativa as proteínas contráteis sensíveis ao cálcio que por sua vez, causam a diminuição da fibra muscular, ou seja, a contração muscular (TORTORA, 2000).


2.4.2 Junção Neuromuscular

É dado o nome de junção neuromuscular para a sinapse entre um neurônio motor somático e uma fibra do músculo esquelético que dá origem aos potenciais de ação no músculo (Figura 4). A sinapse é a região de comunicação entre dois neurônios ou, entre um neurônio e uma célula-alvo – fibra muscular. Na maioria das sinapses existe um vão, chamado fenda sináptica, separando estas duas células. Pelo fato das células não estarem em contato físico, a comunicação é estabelecida através de uma substância química chamada neurotransmissor, a molécula de acetilcolina (ACh) (TORTORA, 2000).

Quando um impulso nervoso chega à placa motora, fibra muscular que faz parte da junção neuromuscular, ocorre a liberação da ACh nas fendas sinápticas. Esta molécula atua aumentando a permeabilidade da membrana aos íons de sódio Na^+ . Ocorre, então, a passagem instantânea de sódio para o interior da fibra muscular, causando a despolarização da membrana muscular. Essa despolarização motiva um potencial de ação que é propagado nas duas direções da fibra muscular, acarretando na sua contração (TORTORA, 2000).

Pouco tempo após a liberação da ACh, é liberada a enzima colinesterase, que se encontra nas pregas subneurais, que transforma a ACh em ácido acético e colina. A destruição da ACh permite que a membrana repolarize, diminuindo a permeabilidade ao sódio, e fique pronta para receber um próximo estímulo (TORTORA, 2000).

Figura 4: Junção Neuromuscular.



Fonte: Adaptado de (OUTTEN *et al.*, 1996).

2.4.3 Unidades Motoras

Um único impulso nervoso em um neurônio motor somático estimula um único potencial de ação muscular em todas as fibras musculares com as quais ele faz sinapse. A tensão total que um músculo pode atingir depende do número de fibras musculares que estão contraindo em conjunto (TORTORA, 2000).

Apesar de cada fibra muscular esquelética possuir somente uma junção neuromuscular, o axônio de um neurônio motor somático se ramifica e forma junções neuromusculares com diversas fibras musculares. Uma unidade motora consiste em um neurônio motor e todas as células esqueléticas que ele estimula, e que, portanto, se contraem juntas. Os músculos envolvidos em um movimento fazem parte de várias pequenas unidades motoras. Por exemplo, os músculos esqueléticos responsáveis por movimentos como o do bíceps braquial, localizado no braço tem de 2000 a 3000 fibras musculares na sua unidade motora (TORTORA, 2000).

2.4.4 Músculos e Movimentos do Braço


Os músculos do braço e antebraço (Figura 5) são projetados para atender às diversas necessidades do corpo ao realizar tarefas diárias complexas. Dentre suas responsabilidades estão a flexão, extensão, supinação e pronação do antebraço e punho, movimentos estudados neste artigo (TORTORA, 2000). A Tabela 1 apresenta alguns dos músculos do segmento mão-braço e os respectivos movimentos nos quais eles estão envolvidos.

Tabela 1: Músculos superficiais do segmento mão-braço e suas funções.

Músculos	Ação
Bíceps braquial	Flexão e supinação do antebraço
Braquial	Flexão do antebraço
Pronador Redondo	Pronação do antebraço
Braquiorradial	Flexão do antebraço
Palmar longo	Flexão do punho
Flexor radial do carpo	Flexão e abdução do punho
Flexor ulnar do carpo	Flexão e adução do punho
Flexor superficial dos dedos	Flexão das falanges dos dedos
Extensor radial do carpo	Extensão e abdução do punho
Extensor ulnar do carpo	Extensão e adução do punho
Extensor dos dedos	Contração da mão

Fonte: Adaptado de (TORTORA, 2000).

Figura 5: Principais músculos superficiais do braço e antebraço.



Fonte: Adaptado de (TORTORA, 2000).

2.5 Captura do Sinal EMG

A atividade bioelétrica no interior do músculo é detectada com a ajuda de eletrodos de EMG. Existem dois tipos principais de eletrodos EMG: eletrodos de superfície e eletrodos invasivos (DE LUCA, 2002).

2.5.1 Eletrodos de Superfície

Os eletrodos de superfície fornecem uma técnica não-invasiva para medição e detecção de sinais de EMG. Basicamente, os eletrodos formam um equilíbrio químico entre a superfície de detecção e a pele do corpo por condução electrolítica, de modo que a corrente pode fluir através do eletrodo (DE LUCA, 2002).

Estes eletrodos são simples e de fácil manuseio. Porém, estes eletrodos são aplicados sobre a pele e são utilizados apenas para captar sinais dos músculos superficiais. A interferência de outros músculos pode ser um grande problema e sua posição deve ser mantida estável com a pele, caso contrário, o sinal é distorcido. Preparações para a pele e precauções especiais, tais como, a remoção de pelos e prevenção de suor, são necessárias para adquirir o melhor sinal possível (DE LUCA, 2002).

2.5.2 Posicionamento dos Eletrodos


Os eletrodos de superfície são relativamente fáceis de usar e não provocam nenhum tipo de desconforto para o usuário, por isto, eles vêm sendo usados, amplamente, nos sistemas de reabilitação através de próteses (LIN *et al.*, 2014), (XING *et al.*, 2014).

A fim de obter os melhores sinais resultantes da atividade muscular, é muito importante ter uma compreensão adequada dos músculos dos quais o sinal está sendo extraído (LIN *et al.*, 2014). Portanto, na Seção 2.4.4 foi realizado um estudo dos músculos envolvidos nos movimentos-alvo deste estudo.

Os eletrodos de superfície devem ser colocados entre a unidade motora e a inserção dos tendões dos músculos, ao longo da linha média longitudinal. O eixo longitudinal dos eletrodos, deve ser paralelo ao comprimento das fibras do músculo (DE LUCA, 2002). Esta combinação de fatores implica num posicionamento adequado do eletrodo e, é ilustrado na Figura 6. Quando os eletrodos são dispostos desta maneira, as superfícies de detecção

intersectam, em grande parte, as mesmas fibras musculares e, como resultado, um sinal sobreposto melhorado é observado (DE LUCA, 2002).

Figura 6: O posicionamento ideal do eletrodo de superfície é entre a unidade motora e a inserção de tendões do músculo.



Fonte: (DE LUCA, 2002).

2.6 Regressão Logística

Em estatística, regressão logística é um tipo de modelo de classificação probabilística. Tipicamente é utilizada para prever o resultado de uma variável dependente de uma ou mais variáveis de previsão independentes. Desta forma, este método pode ser usado para prever as probabilidades de pertencer a uma dada categoria com base nos valores das variáveis preditoras (LAVALLEY, 2002).

A regressão logística pode ser binomial ou multinomial. Regressão logística binomial ou binária lida com situações em que o resultado observado pela variável dependente pode ter apenas dois tipos possíveis. Por outro lado, a regressão logística multinomial lida com situações em que o resultado pode ter três ou mais categorias possíveis (LAVALLEY, 2002), como é o caso deste estudo onde a saída pode referir-se a um dos nove possíveis movimentos reproduzidos durante os ensaios.

Como já mencionado anteriormente, a regressão logística faz uso de uma ou mais variáveis de previsão, que para esta aplicação são representadas por variáveis contínuas que descrevem as características dos sinais, apresentadas na Seção 3.3.5, dos segmentos e canais específicos de um sinal mioelétrico. Ao contrário da regressão polinomial simples, no entanto, a regressão logística é usada para prever resultados discretos dentro da gama de valores viáveis assumidos pela variável dependente em vez de resultados contínuos.

Dada esta diferença, é necessário que a regressão logística aplique o logaritmo natural sobre as probabilidades da variável dependente pertencer a uma classe, operação referida por *logit*, para criar um critério contínuo como uma versão transformada da variável dependente.

Assim, a transformação *logit* é declarada a função de ligação em regressão logística, embora a variável dependente na regressão logística seja binomial para uma determinada classe, o *logit* é um critério contínuo sobre o qual é conduzida a regressão (BISHOP, 2006).

2.6.1 Função Preditora

O primeiro passo para diversas técnicas de classificação estatística, como por exemplo SVM (Support Vector Machine) e regressão logística, é definir uma função preditora que constrói uma pontuação a partir de um conjunto de pesos que são linearmente combinados com as variáveis explicativas usando o produto escalar conforme apresenta a Equação (1) (MCCLELLAND, 2013):

$$\text{score}(X_i, Y_i=k) = \beta_k \cdot X_i = \beta_{0,k} + \beta_{1,k} x_{1,i} + \beta_{2,k} x_{2,i} + \dots + \beta_{C,k} x_{C,i} \quad (1)$$

sendo X_i o vetor de variáveis explicativas que descreve a i -ésima observação/movimento que compõem a base de dados, β_k é um vetor de pesos – coeficientes de regressão – correspondente ao resultado/movimento k , e $\text{score}(X_i, k)$ é a pontuação associada a atribuição da i -ésima observação à categoria k . A diferença entre o modelo de regressão logística multinomial e vários outros métodos com a mesma configuração básica é o processo de determinação dos pesos ótimos – o treinamento – e, a maneira como a função de pontuação é interpretada (MCCLELLAND, 2013).

2.6.2 Função Logística

A função logística ou curva logística sempre assume valores entre zero e um e é definida pela Equação (2), representada graficamente na Figura 7.

$$F(t) = \frac{e^t}{e^t + 1} = \frac{1}{1 + e^{-t}} \quad (2)$$


Se t é visto como a função preditora linear definida pela Equação (1), a função logística pode ser reescrita como:

$$F(X_i, Y_i = k) = Pr(X_i, Y_i = k) = \frac{1}{1 + e^{-(\beta_{0,k} + \beta_{1,k} x_{1,i} + \beta_{2,k} x_{2,i} + \dots + \beta_{C,k} x_{C,i})}} \quad (3)$$

O resultado da Equação (3) é interpretado como a probabilidade de uma dada observação i pertencer à classe k . A função logística se torna extremamente útil pelo fato de poder transformar uma entrada qualquer em uma saída confinada entre 0 e 1 e, portanto, interpretável como uma probabilidade (BISHOP, 2006). Outra definição importante é da função *logit*, inversa da curva logística:

$$g(X_i, Y_i = k) = \ln\left(\frac{F(X_i, k)}{1 - F(X_i, k)}\right) = \beta_{0,k} + \beta_{1,k} x_{1,i} + \beta_{2,k} x_{2,i} + \dots + \beta_{C,k} x_{C,i} = \beta_k \cdot X_i \quad (4)$$

Figura 7: Função logística.



2.6.3 Probabilidade

A formulação da regressão logística binomial como um modelo log-linear pode ser diretamente estendida para a regressão multinomial. Isto é, o modelo é criado através do logaritmo da probabilidade de pertencer a uma dada categoria, bem como, de um fator de normalização adicional Z :

$$\ln(Pr(Y_i = 1)) = \beta_1 \cdot X_i - \ln(Z) \quad (5)$$

$$\ln(Pr(Y_i = 2)) = \beta_2 \cdot X_i - \ln(Z) \quad (6)$$

...

$$\ln(\Pr(Y_i=K))=\beta_K \cdot X_i - \ln(Z) \quad (7)$$

Assim como no caso binomial, é necessário que o termo extra $-\ln(Z)$ garanta que o conjunto de probabilidades forme uma distribuição de probabilidade, isto é, deve somar um:

$$\sum_{k=1}^K \Pr(Y_i=k) = 1 \quad (8)$$

A razão pela qual é preciso adicionar um termo para garantir a normalização, ao invés de multiplicar, como é habitual, é porque é aplicado o logaritmo das probabilidades. Exponencializando ambos os lados das equações semelhantes à Equação (5) o termo adicional é transformado em um fator multiplicativo:

$$\Pr(Y_i=1) = \frac{1}{Z} e^{\beta_1 \cdot X_i} \quad (9)$$

$$\Pr(Y_i=2) = \frac{1}{Z} e^{\beta_2 \cdot X_i} \quad (10)$$

...

$$\Pr(Y_i=K) = \frac{1}{Z} e^{\beta_K \cdot X_i} \quad (11)$$

Aplicando as Equações (9), (10) e (11) na restrição descrita pela Equação (8) é obtido:

$$Z = \sum_{k=1}^K e^{\beta_k \cdot X_i} \quad (12)$$

Substituindo o valor encontrado pela Equação (12) nas equações semelhantes à Equação (9) encontramos a função *softmax*. Em probabilidade e áreas afins, a função *softmax* é uma generalização da função logística que redefine um vetor K -dimensional de valores reais arbitrários como um vetor K -dimensional de valores reais no intervalo $[0, 1]$ (YUN *et al.*, 2008). A função é portanto, dada por:

$$\text{softmax}(Y_i=k, X^T \cdot \beta) = Pr(Y_i=k|X) = \frac{e^{X^T \cdot \beta_k}}{\sum_{n=1}^K e^{X^T \cdot \beta_n}} \quad (13)$$

O fato de realizar a exponencial dos componentes $X^T \cdot \beta_n$ implica em exagerar a diferença entre eles. Como resultado, *softmax* retornará um valor próximo de zero quando $X^T \cdot \beta_k$ for significativamente menor do que o valor máximo, e retornará um valor próximo de um, quando representar o valor máximo, a menos que seja extremamente estreita a diferença para o próximo maior valor. Uma vez que o somatório dos resultados da Equação (13) para os diferentes valores de k resulta em um e os componentes estão estritamente entre zero e um, esta função representa uma distribuição de probabilidade categórica. Por esta razão, a função *softmax* é usada em vários métodos de classificação probabilística multinomial incluindo a regressão logística multinomial. Pode-se interpretá-la como a probabilidade de o vetor amostral X pertencer a classe k (YUN *et al.*, 2008).

2.6.4 Estimação dos Parâmetros

Dado um conjunto de treinamento é necessário estimar os coeficientes de regressão que vão definir as probabilidades de uma dada amostra pertencer a uma dada categoria de movimentos. A minimização da função de custo, descrita pela Equação (14), formaliza a obtenção dos parâmetros β que melhor descrevem os dados de treinamento (LAVALLEY, 2008).

$$J(\beta) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{k=1}^K 1\{Y_i=k\} \log Pr(Y_i=k|X_i) \right] \quad (14)$$

onde, m é o número de exemplos rotulados e K é o número de rótulos diferentes que uma variável de saída pode tomar.

Para métodos de regressão que usam a função *softmax* uma propriedade incomum manifesta-se: a redundância do conjunto de parâmetros. Isto é, se a função custo $J(\beta)$ é minimizada para os parâmetros $\{\beta_1, \beta_2, \dots, \beta_C\}$, então ela também é minimizada por $\{\beta_1 - \Psi, \beta_2 - \Psi, \dots, \beta_C - \Psi\}$ para qualquer valor de Ψ . Portanto, a solução de minimização de $J(\beta)$ não é única (LAVALLEY, 2008).

Através da adição de um fator na função custo é possível penalizar a escolha de valores altos como parâmetros. Com esta modificação a função custo torna-se estritamente convexa, para $\lambda > 0$, e, conseqüentemente, garante uma solução única (LAVALLEY, 2008). A função custo modificada é definida como:

$$J(\beta) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{j=1}^K 1\{Y_i=j\} \log Pr(Y_i=j|X_i) \right] + \frac{\lambda}{2} \sum_{i=1}^K \sum_{j=0}^N \beta_{ij}^2 \quad (15)$$

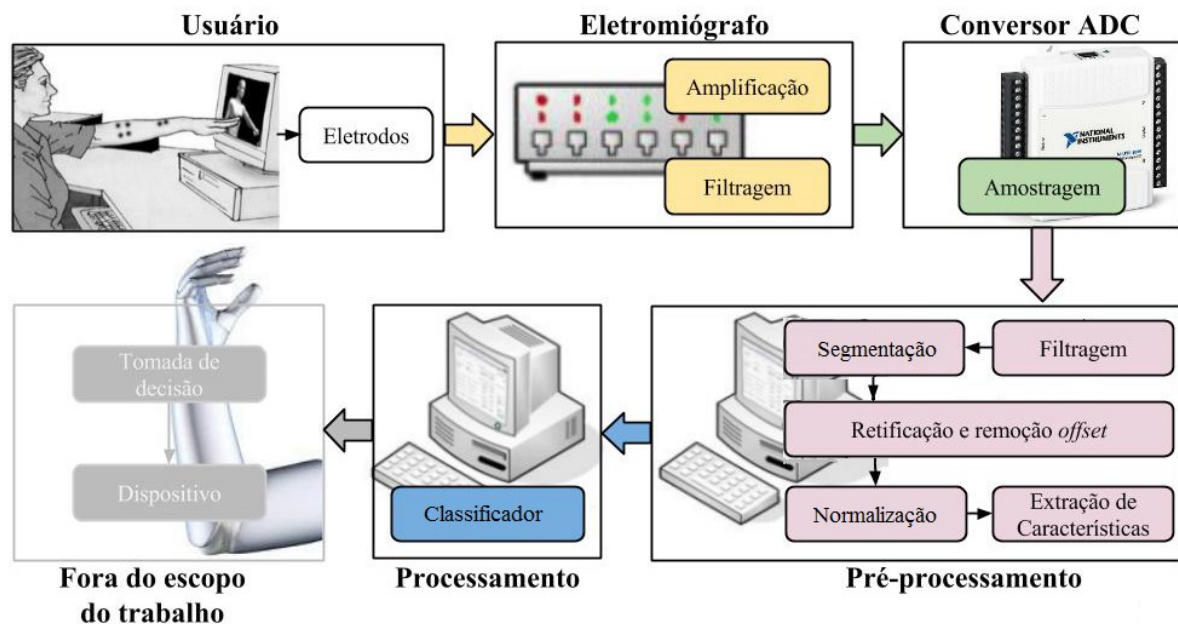
A parte da Equação (15) denotada por $1\{Y_i=k\}$ determina que apenas a saída do classificador correspondente à classe correta está incluída no custo. Dada a convexidade da Equação (15) pode-se garantir a convergência de algoritmos de minimização como L-BFGS (*Limited-memory Broyden-Fletcher-Goldfarb-Shanno*). Além da função de custo é necessário fornecer seu gradiente para que este tipo de algoritmo possa processar (LAVALLEY, 2008). O gradiente de $J(\beta)$ é apresentado a seguir:

$$\nabla_{\beta_j} J(\beta) = -\frac{1}{m} \sum_{i=1}^M [X_i (1\{Y_i=j\} - Pr(Y_i=j|X_i; \beta))] + \lambda \beta_j \quad (16)$$

3 METODOLOGIA EXPERIMENTAL

A Figura 8 ilustra os principais componentes do sistema experimental proposto neste trabalho baseado no reconhecimento de padrões de sinais mioelétricos. O sistema é constituído de um eletromiógrafo, equipamento responsável pela amplificação e filtragem analógica do sinal captado pelos eletrodos não invasivos. Durante os ensaios de captura de sinais EMG de uma sequência de movimentos, setes pares de eletrodos neonatais de superfície são posicionados nos músculos estratégicos do segmento mão-braço listados na Tabela 2; e, um eletrodo de referência é posicionado na testa, região de baixa atividade muscular. Os voluntários são informados da natureza dos procedimentos a que serão submetidos e orientados a assinar um Termo de Consentimento Livre e Esclarecido, contendo explicações e possíveis riscos que podem ocorrer.

Figura 8: Esquema do sistema experimental do projeto.



No software *LabVIEW*, foi desenvolvido um programa para executar vídeos (CONTO & BALBINOT, 2011), que padronizam movimentos, e para adquirir dados. Os vídeos contêm o modelo virtual que demonstra ao voluntário a sequência de movimentos que devem ser imitados e, posteriormente, portanto, servirão para rotular os dados de aprendizagem do classificador. Ao realizar os movimentos, os sinais mioelétricos são obtidos através do eletromiógrafo e, posteriormente, digitalizados por uma placa conversora analógica digital. O sinal resultante é armazenado em um computador onde os dados são pré-processados e

processados por intermédio dos programas desenvolvidos em *LabVIEW*, *MATLAB* e *Python*. Nos próximos subcapítulos são apresentadas discussões completas de cada um destes blocos.

Tabela 2: Movimentos de ativação dos músculos escolhidos para caracterizar os movimentos.

Canal	Músculos	Ação
0	Bíceps Braquial	Flexão do Antebraço
1	Flexor Radial do Carpo	Abdução do Punho
2	Flexor Ulnar do Carpo	Adução do Punho
3	Extensor dos Dedos	Contração da Mão
4	Pronador Redondo	Pronação do Antebraço
6	Palmar Longo	Flexão do Punho
7	Extensor Ulnar do Carpo	Extensão do Punho

3.1 Plataforma de hardware

3.1.1 Eletromiógrafo

O eletromiógrafo é um aparelho utilizado para detectar o potencial elétrico gerado por células musculares quando essas células são eletricamente ou neurologicamente ativadas. A observação simultânea dos sinais e das grandezas físicas envolvidas nos movimentos reproduzidos durante os ensaios foi realizada pelo eletromiógrafo *EMG 830 C* da *EMG System do Brasil*.

3.1.2 Sistema de aquisição de dados

A etapa de aquisição de dados conta com o dispositivo *NI USB 6008* da *National Instruments*. Além de oferecer funções básicas de aquisição também é possível programá-la através do *NI LabVIEW* para obter um sistema de medição customizado.

A ficha técnica deste dispositivo alinha-se com as necessidades da aplicação deste trabalho pois, apresenta oito canais de entrada analógica, suficientes para serem conectados aos sinais capturados pelos eletrodos ligados ao eletromiógrafo, com resolução de 12 bits e taxa de amostragem de 10.000 amostras/s. Além disto, possui uma tensão de entrada máxima

para os canais analógicos de ± 10 V, tensão compatível com a saída do eletromiógrafo, com taxa de aquisição de 1 kHz.

3.2 Plataforma de software

A linguagem de programação escolhida para o desenvolvimento da parte de aquisição de dados do *software* do sistema proposto é o *LabVIEW*. O *LabVIEW* (*Laboratory Virtual Instrument Engineering Workbench*) é uma plataforma de programação gráfica originária da *National Instruments* que oferece integração com o hardware de aquisição de dados, bibliotecas de processamento de sinais e controles de interface de usuário desenvolvidos para a visualização dos dados das medições.

A programação é feita de acordo com o modelo de fluxo de dados, o que oferece a esta linguagem vantagens para a aquisição de dados e para a sua manipulação. Os programas em *LabVIEW* são chamados de instrumentos virtuais ou, simplesmente, VI. São compostos pelo painel frontal, que contém a interface, e pelo diagrama de blocos, que contém o código gráfico do programa. O programa não é processado por um interpretador, mas sim compilado. Deste modo seu desempenho é comparável ao exibido pelas linguagens de programação de alto nível.

3.2.1 Modelo Virtual

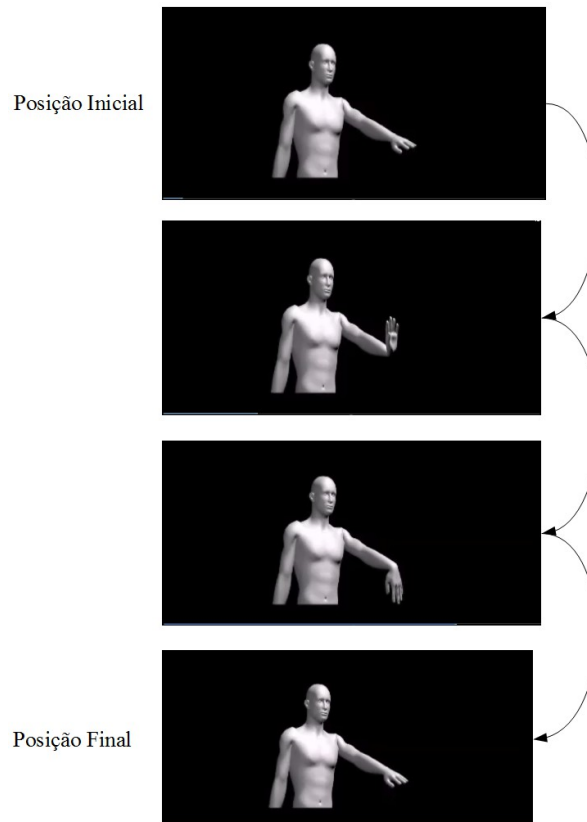
Sabendo que o principal objetivo deste trabalho é prever movimentos do segmento mão-braço utilizando um método de regressão, é imprescindível que seja criado um banco de dados de treinamento. Este conjunto serve como um mapa de referência e, portanto, tem a saída conhecida. Isto é, ao coletar-se os dados para este foco, deve-se saber quais movimentos estão sendo executados para que seja possível alimentar o classificador e assim, obter resultados de sucesso em outros casos.

O modelo virtual foi criado com o objetivo de elaborar um banco de dados de treinamento consistente, permitindo que o voluntário tenha uma referência visual reproduzindo gestos pré-definidos e, que posteriormente, serão associados, corretamente, a segmentos do sinal. Sendo assim, os movimentos virtuais são um padrão a ser seguido por todos os voluntários que comporão o banco de dados de treinamento.

As animações que contém os movimentos simples e compostos à serem repetidos foram criadas e desenvolvidas por (BALBINOT & CONTA, 2011), utilizando os softwares

MakeHuman 1.0 Alpha5 e *Blender 2.54 Beta*. A Figura 9, por exemplo, apresenta o movimento composto de extensão e flexão do punho, como é observado no procedimento das animações, tendo uma posição inicial e final padronizada.

Figura 9: Animação do movimento composto de Extensão e Flexão do Punho.



Fonte: Adaptado de CONTO & BALBINOT, 2011.

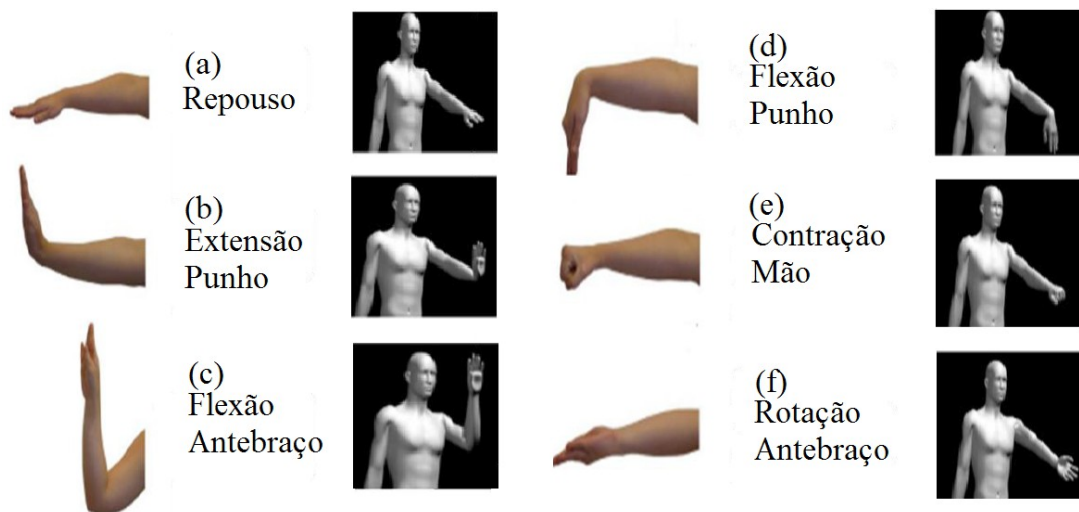
3.2.1.1 Movimentos

Os movimentos do segmento mão-braço escolhidos para compor os ensaios deste trabalho são classificados em simples e compostos. Os movimentos simples designados foram a Contração da Mão (CM), a Extensão do Punho (EP), a Rotação do Antebraço (RA), a Flexão do Punho (FP) e a Flexão do Antebraço (FA). Os referidos estão ilustrados na Figura 10.

De um modo geral os movimentos compostos podem ser tratados como a superposição dos movimentos simples listados anteriormente. Para este trabalho foram selecionadas as seguintes associações: Rotação do Antebraço com Flexão do antebraço (RAF), Rotação do Antebraço com Contração da mão (RAC), Extensão seguida de Flexão do Punho (EFP) e,

Contração da Mão e Flexão do antebraço (CMF). Esta classe de movimentos está, igualmente, ilustrada na Figura 11. Foi padronizada a posição de repouso como sendo a disposição do antebraço ilustrada na Figura 10.(a) e, como mencionado na Seção 3.2.1, representa a padronização da posição inicial e final dos movimentos. Este posicionamento é utilizado na intercalação dos movimentos simples e compostos descritos, durante a realização das séries.

Figura 10: Movimentos simples: (a) repouso, (b) Extensão do Punho, (c) Flexão do Antebraço, (d) Flexão do Punho, (e) Contração da Mão e (f) Rotação do Antebraço.



Fonte: Adaptado de (FAVIERO, 2012).

Com base nas informações apresentadas na Tabela 1, a Tabela 3 apresenta novamente, para uma melhor compreensão do trabalho, os músculos relacionados aos movimentos selecionados para este estudo.

Tabela 3: Músculos superficiais do segmento mão-braço e movimentos selecionados que os ativam.

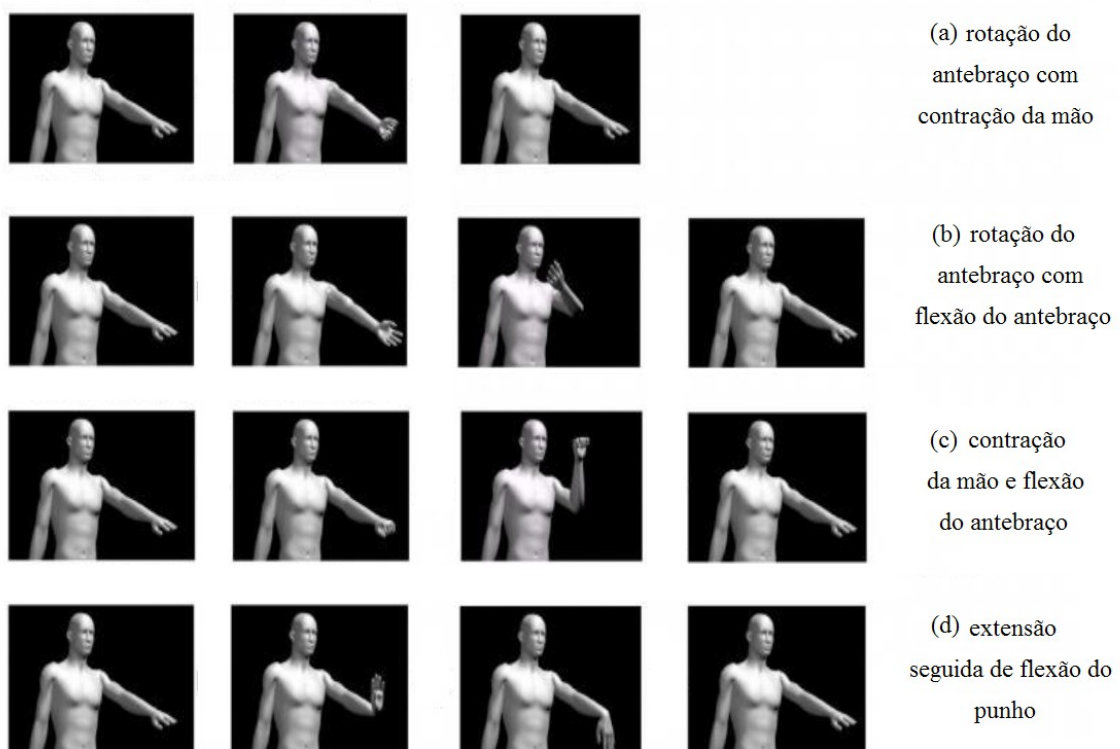
Músculos	Movimentos
Bíceps Braquial	RA, FA, RAF, RAC, CMF
Braquial	FA, RAF, CMF
Pronador Redondo	RA, RAF, RAC
Braquiorradial	FA, RAF, CMF
Palmar Longo	FP, EFP
Flexor Radial do Carpo	FP, EFP
Flexor Ulnar do Carpo	FP, EFP

Continuação da Tabela 3.

Flexor Superficial dos Dedos	CM, RAC, CMF
Extensor Radial do Carpo	EP, EFP
Extensor Ulnar do Carpo	EP, EFP
Extensor dos Dedos	CM, RAC, CMF

CM: Contração da Mão, EP: Extensão do Punho, RA: Rotação do Antebraço, FP: Flexão do Punho, FA: Flexão do Antebraço, RAF: Rotação do Antebraço com Flexão do antebraço, RAC: Rotação do Antebraço com Contração da mão, EFP: Extensão seguida da Flexão do Punho e CMF: Contração da Mão e Flexão do antebraço.

Figura 11: Movimentos compostos: (a) Rotação do Antebraço com Flexão do antebraço, (b) Rotação do Antebraço com Contração da mão, (c) Extensão seguida de Flexão do Punho e, (d) Contração da Mão e Flexão do antebraço.



Fonte: Adaptado de (FAVIERO, 2012).

3.2.1.2 Séries

As séries de movimentos do segmento mão-braço, apresentadas pelo modelo virtual, são constituídas pela aglutinação dos movimentos simples e compostos intercalados por

repouso anunciados na Seção 3.2.1.1. Todas as séries começam na posição de repouso, executam algum dos movimentos simples ou compostos e, voltam ao repouso e assim, sucessivamente, até totalizar um tempo de 250 s de aquisição de sinal. A Tabela 4 apresenta as seis séries usadas nos ensaios.

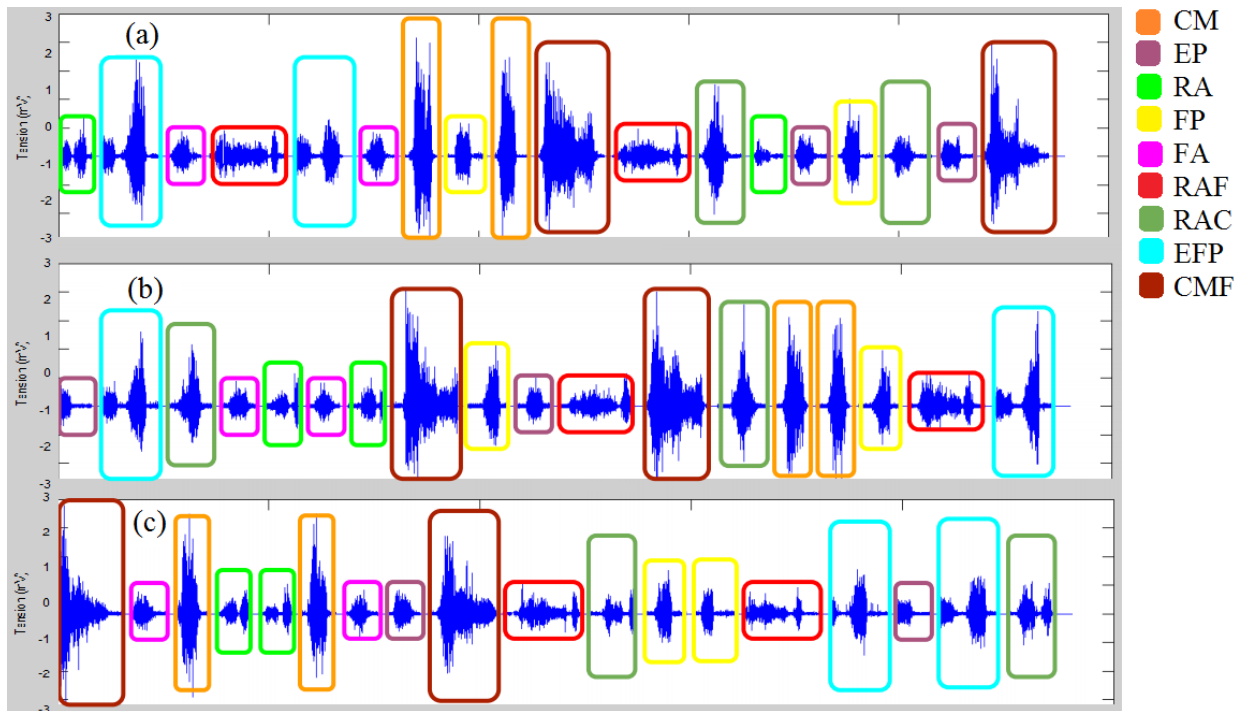
Tabela 4: Série de movimentos.

Série	Movimentos																	
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
1	RA	EFP	FA	RAF	EFP	FA	CM	FP	CM	CMF	RAF	RAC	RA	EP	FP	RAC	EP	CMF
2	EP	EFP	RAC	FA	RA	FA	RA	CMF	FP	EP	RAF	CMF	RAC	CM	CM	FP	RAF	EFP
3	CMF	FA	CM	RA	RA	CM	FA	EP	CMF	RAF	RAC	FP	FP	RAF	EFP	EP	EFP	RAC
4	FP	EP	RA	RAC	RA	RAC	FA	FP	FA	CM	CM	CMF	EFP	CMF	EP	RAF	EFP	RAF
5	CM	CMF	RAC	RA	CMF	EP	RAF	EFP	FA	RA	RAC	FA	FP	EP	CM	FP	EFP	RAF
6	CMF	EFP	FA	EP	FA	RA	EP	CMF	RAC	CM	EFP	RAC	FP	RA	RAF	FP	RAF	CM

CM: Contração da Mão, EP: Extensão do Punho, RA: Rotação do Antebraço, FP: Flexão do Punho, FA: Flexão do Antebraço, RAF: Rotação do Antebraço com Flexão do antebraço, RAC: Rotação do Antebraço com Contração da mão, EFP: Extensão seguida da Flexão do Punho e CMF: Contração da Mão e Flexão do antebraço.

A Figura 12 apresenta os sinais adquiridos durante a execução da série 1, série 2 e série 3 listadas na Tabela 4 para o canal associado ao palmar longo. Analisando a Figura 12 é possível observar um comportamento característico dos sinais indicados pelos retângulos que demonstram o sinal ativo em um dado movimento. O escopo deste estudo é justamente configurar e prever este comportamento característico. Cada série tem um total de 250 s e os movimentos são intercalados por repousos de 3 s.

Figura 12: (a) Série 1, (b) Série 2 e (c) Série 3.



CM: Contração da Mão, EP: Extensão do Punho, RA: Rotação do Antebraço, FP: Flexão do Punho, FA: Flexão do Antebraço, RAF: Rotação do Antebraço com Flexão do antebraço, RAC: Rotação do Antebraço com Contração da mão, EFP: Extensão seguida da Flexão do Punho e CMF: Contração da Mão e Flexão do antebraço.

3.2.2 Procedimento para aquisição dos dados

A rotina de aquisição do banco de dados foi implementada na plataforma *LabVIEW*. Os dados são adquiridos por intermédio da placa *NI USB 6009* e salvos em um arquivo com extensão “.lvm” (*LabVIEW Measurement*). Este arquivo contém uma tabela na qual a primeira coluna é a coluna temporal, iniciada em zero e sendo acrescida de 1 ms por linha portanto, seguindo a definição de frequência de aquisição de 1 kHz; e, outras oito colunas representando a tensão elétrica nos canais de aquisição, descrevendo, portanto, a atividade muscular em cada um dos músculos estratégicos. A Figura 13 apresenta uma parte deste arquivo de saída gerado após a execução de um ensaio de aquisição de sinal.

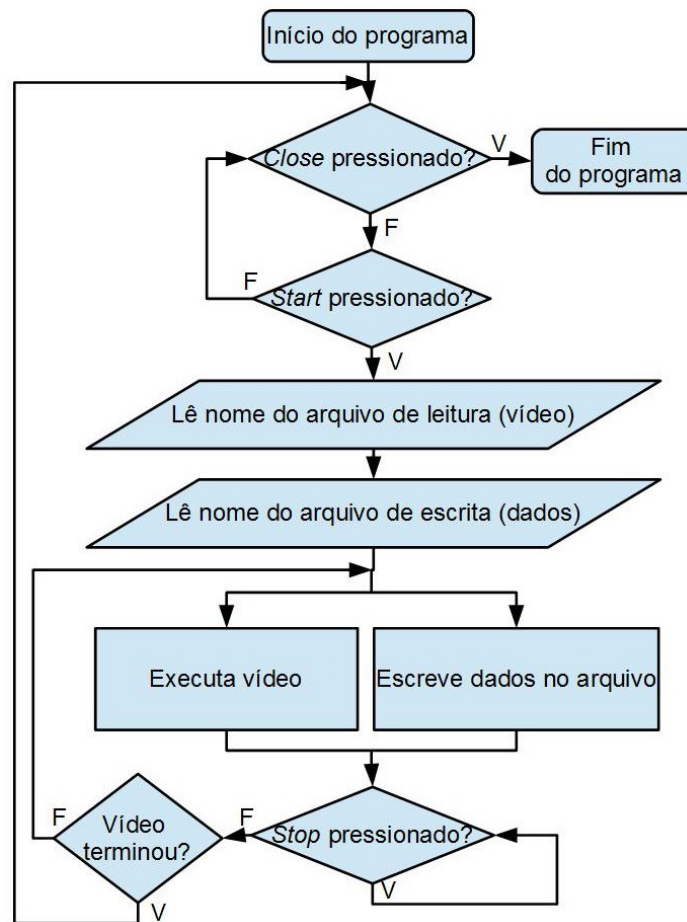
Figura 13: Arquivo de aquisição de dados ".lvm".

[s]	1	2	3	4	5	6	7	8	[mV]
0.000000	0.037235	-1.376804	0.067197	0.018301	0.006228	1.392842	0.013611	0.005394	
0.001000	0.048694	-1.380621	-0.010468	0.036128	-0.003958	1.397934	-0.004215	-0.030269	
0.002000	0.072884	-1.375532	-0.136515	0.034854	0.016414	1.397934	-0.009308	-0.030269	
0.003000	0.084343	-1.390801	-0.223093	-0.022447	0.001135	1.390295	-0.011854	-0.009890	
0.004000	0.118719	-1.399708	-0.132695	-0.109035	-0.003958	1.403027	-0.022040	0.041057	
0.005000	0.133997	-1.416250	-0.062669	-0.121769	-0.009051	1.397934	-0.027133	0.074172	
0.006000	0.117446	-1.411161	-0.055030	-0.161243	-0.014144	1.395388	-0.006761	0.137856	
0.007000	0.118719	-1.421340	-0.085587	-0.111582	-0.014144	1.395388	-0.009308	0.038510	
0.008000	0.123812	-1.430247	-0.001556	0.039948	-0.016690	1.392842	-0.009308	-0.093953	
0.009000	0.093255	-1.426430	0.036640	0.074328	-0.011597	1.397934	-0.009308	-0.121974	
0.010000	0.060153	-1.406071	0.031548	0.038674	0.006228	1.397934	0.000878	-0.055742	
0.011000	-0.031516	-1.412433	0.041733	-0.002073	0.001135	1.395388	0.008518	0.002847	
0.012000	-0.079897	-1.399708	0.029001	0.037401	0.006228	1.405574	0.023797	0.025773	
0.013000	-0.073531	-1.383166	0.016269	-0.012260	0.018960	1.390295	0.018704	0.076720	
0.014000	-0.070985	-1.370442	0.059558	0.022121	0.003682	1.395388	0.033983	0.035962	
0.015000	-0.063346	-1.353900	0.099027	0.069235	0.006228	1.397934	0.031436	-0.027722	
0.016000	-0.063346	-1.366624	0.115579	0.070508	-0.001411	1.392842	0.008518	-0.055742	
0.017000	-0.069712	-1.376804	0.077383	0.069235	-0.009051	1.403027	0.000878	-0.106689	
0.018000	-0.051887	-1.371714	0.012450	0.050135	0.008774	1.397934	-0.006761	-0.068479	
0.019000	-0.039155	-1.381894	-0.055030	0.013207	0.003682	1.390295	-0.004215	-0.007343	

O tempo de aquisição é definido pela duração do vídeo referente ao modelo virtual da série sendo executada. A partir do momento em que o vídeo é iniciado, automaticamente, o indivíduo deve reproduzir os movimentos retratados na tela e assim, os seus dados, atividade muscular, começam a ser salvos. Analogamente, ao final da execução do vídeo a aquisição é, automaticamente, finalizada. Esta sincronização automática é possível graças a consideração do atraso de execução do usuário levada em conta durante a edição dos vídeos que, portanto, estendem-se para abranger instantes após o último movimento.

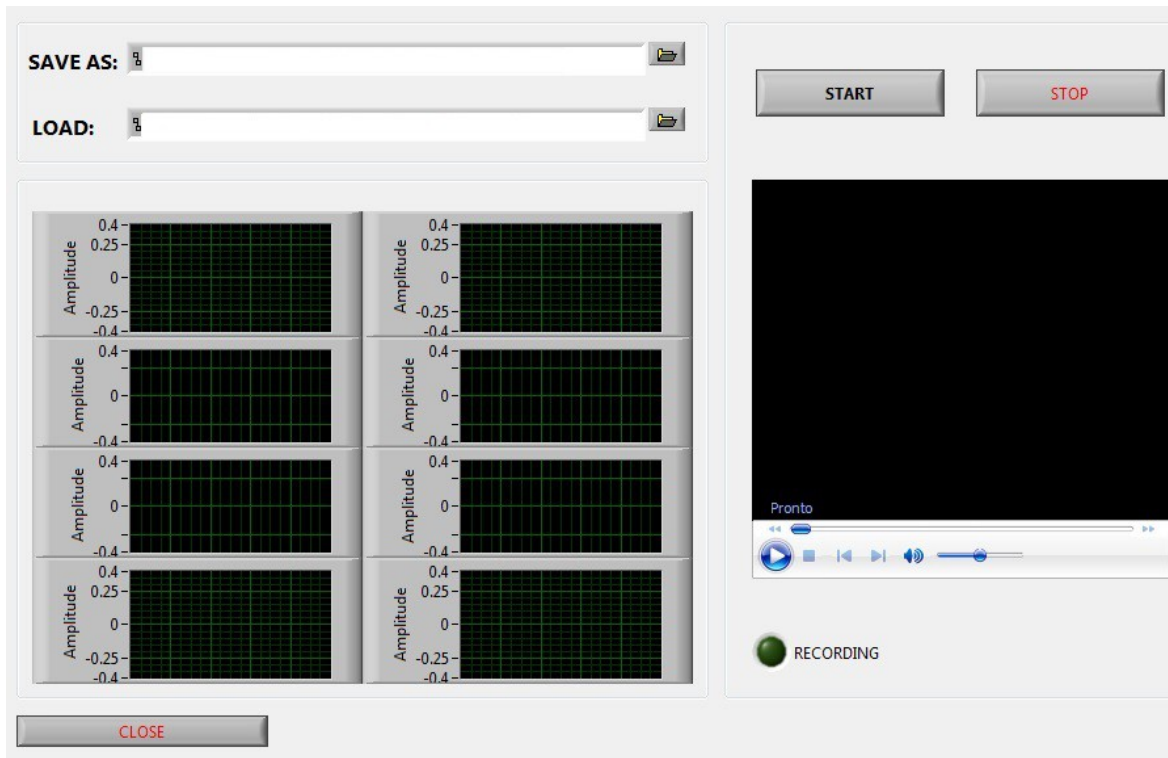
Antes de iniciar o ensaio o usuário deve portanto, selecionar o vídeo referente à série que deseja executar assim como, fornecer o nome do arquivo de extensão “.lvm” no qual os dados serão salvos. Após estes passos basta iniciar a aquisição pressionando o botão *Start*. Caso algum problema ocorra ao transcorrer da execução da série é possível pausá-la, sem nenhum prejuízo para a formação do banco de dados, pressionando o botão *Stop*. Uma vez que o ensaio for concluído pressiona-se o botão *Close*, fechando o programa. A Figura 14 apresenta o fluxograma que resume o funcionamento do programa de formação do banco de dados. O APÊNDICE – LabVIEW: AQUISIÇÃO apresenta o diagrama de blocos desenvolvido no *LabVIEW*.

Figura 14: Fluxograma do programa de aquisição.



Para facilitar o acompanhamento dos ensaios, a interface, apresentada na Figura 15, apresenta o gráfico de tensão elétrica por tempo dos oito canais do eletromiógrafo conectados a placa de aquisição. Caso algum problema seja identificado, como por exemplo a apresentação de um canal excessivamente ruidoso podendo ter sua causa originária no mal posicionamento de um eletrodo, o ensaio pode ser pausado através do botão *Stop*, como já mencionado no parágrafo anterior.

Figura 15: Interface do sistema de aquisição.



3.2.3 Procedimento de calibração

A calibração do sistema é uma das primeiras etapas na realização de um ensaio. Ela é responsável por averiguar o bom posicionamento dos eletrodos e, também, personalizar o sinal do indivíduo para, posteriormente, segmentá-lo de forma adequada após a aquisição dos sinais.

Cada músculo possui um movimento característico, apresentado, anteriormente, na Tabela 2, e, portanto, quando é desejado calibrar um determinado canal, pressionando o botão correspondente na interface, um vídeo que combina repouso e o movimento em questão, que deve ser replicado com contração voluntária máxima (CVM), é reproduzido. O bom posicionamento do eletrodo é determinado pela razão entre o valor de pico do sinal apanhado durante o movimento com CVM e o valor do momento de relaxamento. Este resultado imprescindível para a calibração de um canal será referenciado por RCR (Relação Contração máxima Relaxamento).

Uma vez que o canal é considerado calibrado, ou seja, o RCR é maior que um, seu valor é salvo em um arquivo chamado “*RMS_MVC_relaxed.txt*”, ilustrado na Figura 16, que será, posteriormente, indispensável para a etapa de segmentação, detalhada na Seção 3.3.4. Este arquivo descreve características do sinal muscular da pessoa que utilizará o sistema, visto

que cada indivíduo possui uma atividade muscular diferenciada. Sendo assim, a calibração consegue fazer com que o sistema seja genérico e, por consequência, se adapte aos diferentes usuários. O fluxograma exibido na Figura 17 descreve com maiores detalhes o funcionamento completo desta rotina e, a Figura 18 apresenta a interface disponibilizada ao operador deste procedimento. O APÊNDICE – LabVIEW: Calibração apresenta o diagrama de blocos desenvolvido no *LabVIEW*.

Figura 16: Arquivo gerado durante a etapa de calibração dos canais do Voluntário 2.

	MVC	relaxed
C0	0.19770	0.03848
C1	0.04150	0.00997
C2	0.70051	0.03985
C3	0.18094	0.03756
C4	0.07874	0.00984
C5	0	0
C6	0.29059	0.01390
C7	0.65115	0.07088

Figura 17: Fluxograma do programa de calibração.

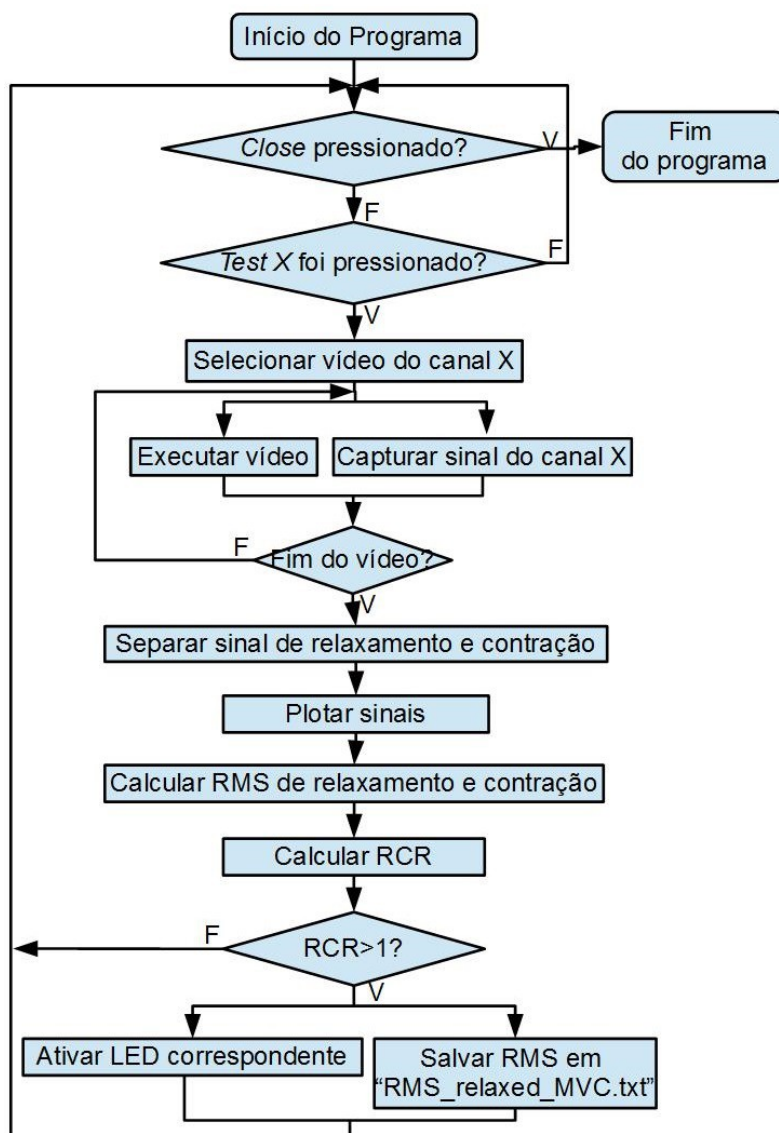
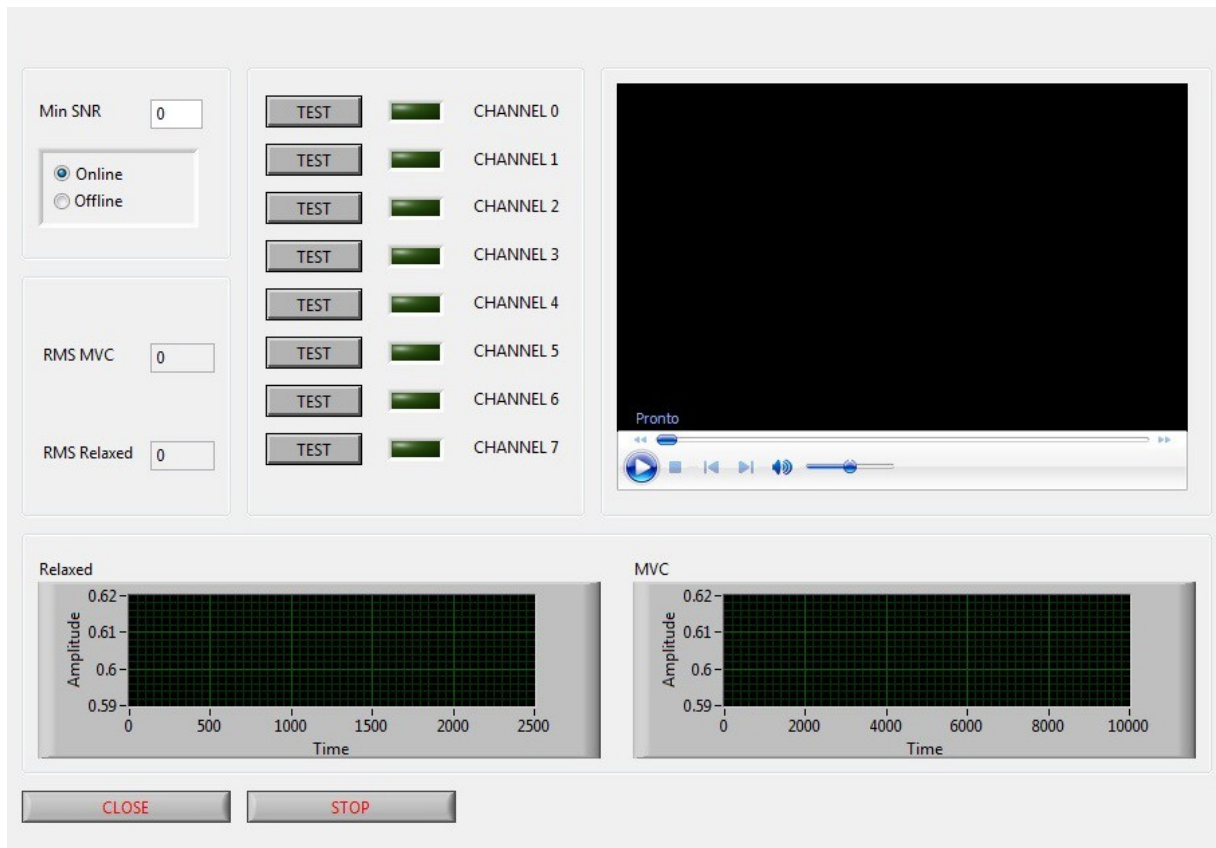


Figura 18: Interface da rotina de calibração.



3.3 Pré-processamento do sinal mioelétrico

Após a aquisição do sinal de EMG o mesmo é tratado, matematicamente, no bloco de pré-processamento com o objetivo de fornecer informações pertinentes e robustas ao módulo de caracterização do sinal, o processamento. Essa etapa consiste na retificação, remoção do *offset*, filtragem, normalização e segmentação do sinal de interesse. As características utilizadas neste trabalho são: RMS, variância, desvio padrão e obliquidade. Essas características são os parâmetros de entrada do classificador. Nos próximos subcapítulos são apresentadas discussões de cada um destes blocos.

3.3.1 Retificação de Onda Completa

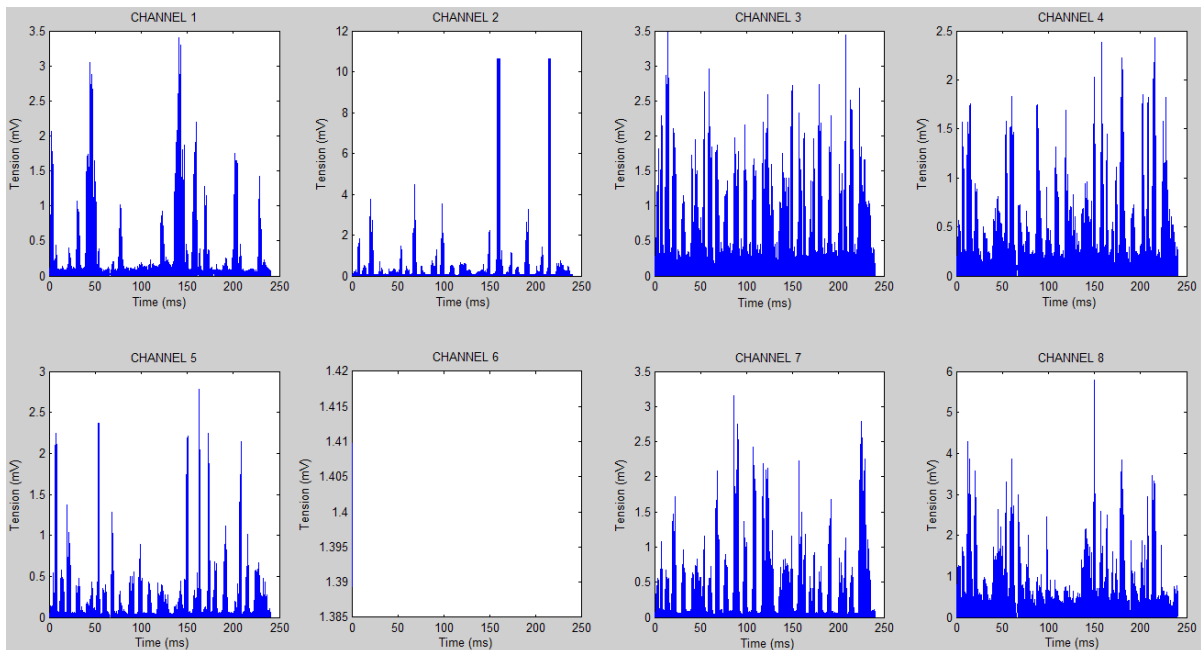
A retificação, técnica amplamente utilizada quando se quer realizar a integração de um sinal, consiste na obtenção de um sinal EMG exclusivamente positivo. Uma das formas de

alcançar esta configuração, sem perda de energia, é através do cálculo do módulo do sinal (Equação (17)), onde as etapas negativas são rebatidas e não eliminadas. A Figura 19 apresenta o resultado desta operação sobre o sinal resultante de sete canais de um dos ensaios. O procedimento é realizado através do código *MATLAB*:

```
SIGNAL_RET=abs(SIGNAL);
```

$$EMG_{RET}(t) = |EMG(t)| \quad (17)$$

Figura 19: Sinal retificado.



3.3.2 Remoção do *offset*

O componente DC pode ser adicionado ao sinal mioelétrico no momento da aquisição do sinal. O procedimento adotado para o ajuste de *offset* foi calcular o componente DC (Equação (18)), através da média aritmética do sinal mioelétrico, e subtraí-lo do sinal mioelétrico (Equação (19)). O resultado desta sequência de operações pode ser observado na Figura 20. O procedimento é descrito pelo código *MATLAB*:

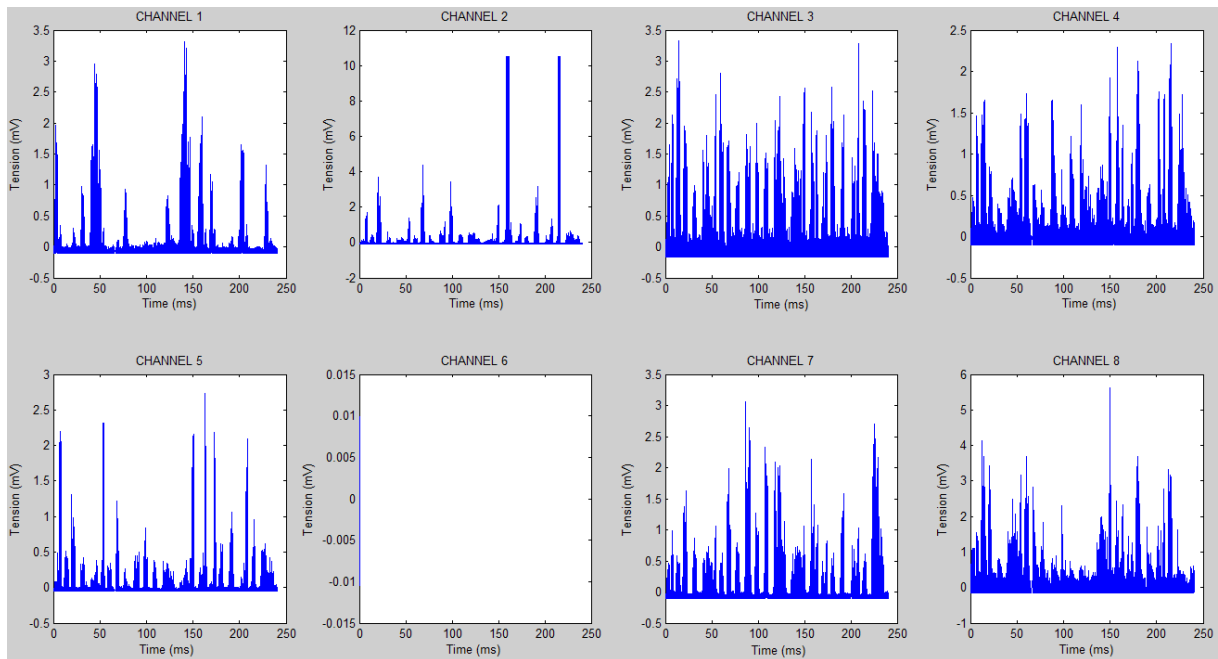
```
DC=sum(SIGNAL)/numel(SIGNAL);  
SIGNAL_OFF=SIGNAL-DC;
```

$$DC = \frac{\sum_{t=0}^N EMG(t)}{N} \quad (18)$$

onde N é o número de amostras extraídas do sinal de EMG durante o tempo de aquisição.

$$EMG_{OFF}(t) = EMG(t) - DC \quad (19)$$

Figura 20: Sinal após operação de offset.



3.3.3 Filtragem

O sinal eletromiográfico é, inevitavelmente, contaminado por fontes intrínsecas e extrínsecas de baixa frequência. As duas principais fontes extrínsecas de ruído são as advindas da fonte de alimentação e da movimentação do cabo, que podem ser quase totalmente eliminadas pelos equipamentos modernos e circuitos apropriados. Já as fontes intrínsecas são representadas pelo ruído de linha de base e pelo ruído de movimento de artefato, detectado sempre que um eletrodo é anexado à pele (DE LUCA *et al.*, 2010).

O filtro escolhido para remover o ruído de artefato de movimento foi o *Butterworth* passa-alta de quarta ordem pelo fato de exibir menos *overshoot* e ter um tempo de resposta

menor aos sinais transientes segundo os estudos realizados por (DE LUCA *et al.*, 2010). O procedimento é descrito pelo código *MATLAB*:

```
% High-pass filter
high_filter = fdesign.highpass('n,f3db',filterOrder,(2*cutOffHighFreq)/sampleRate);
H1 = design(high_filter,'butter');
highpass_EMG = filter(H1, SIGNAL);
% Low-pass filter
low_filter = fdesign.lowpass('n,f3db',filterOrder,(2*cutOffLowFreq)/sampleRate);
H2 = design(low_filter,'butter');
SIGNAL_FILTERED = filter(H2,highpass_EMG);
```

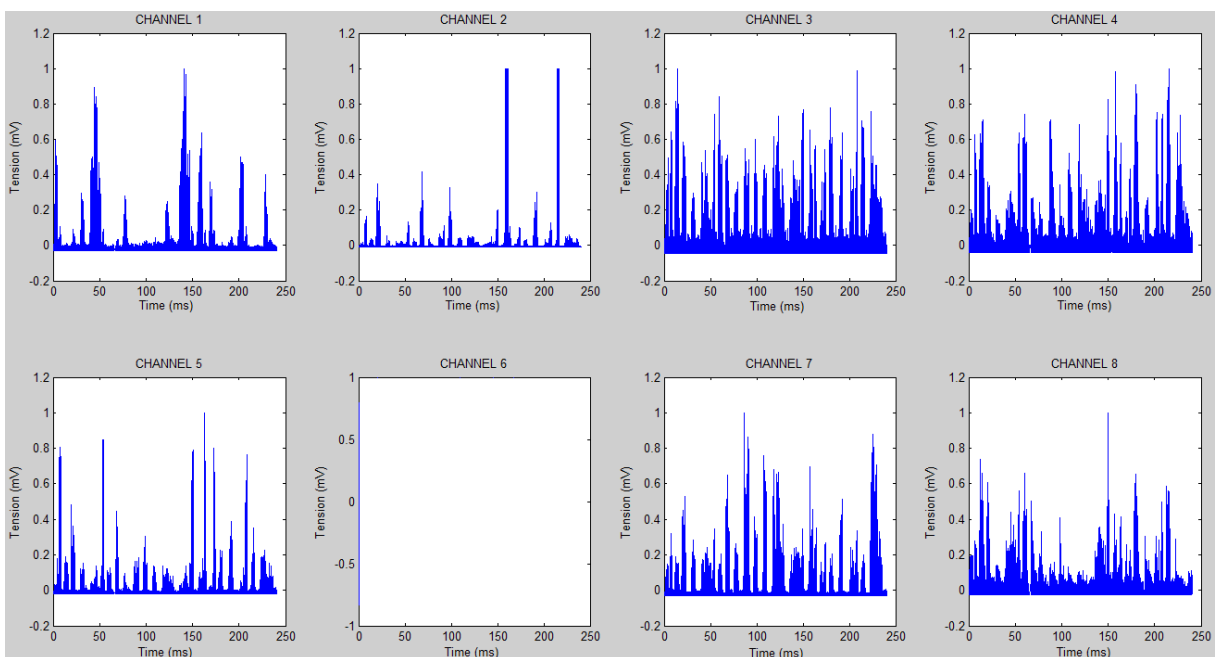
3.3.3 Normalização

Um estudo revela que dados submetidos a normalização antes do treinamento apresentam melhores resultados finais (HSU *et al.*, 2003). Esta operação é definida pela Equação (20) e o respectivo resultado sobre um dos ensaios realizados é ilustrado pela Figura 21. O procedimento é descrito pelo código *MATLAB*:

```
SIGNAL_N=SIGNAL/max(abs(SIGNAL));
```

$$EMG_N(t) = \frac{EMG(t)}{\max(|EMG(t)|)} \quad (20)$$

Figura 21: Sinal normalizado.



3.3.4 Segmentação

Um segmento é um intervalo de tempo dedicado ao registro de dados mioelétricos significativos encaminhados para a extração de características. A Figura 22 e a Figura 23 expõe o resultado do procedimento utilizado para segmentação aplicado aos canais 1 e 7, respectivamente. Este método é relatado a seguir:

1. dividir o sinal mioelétrico em janelas de 250 ms. O tempo de segmentação foi determinado com base na duração de cada movimento e no repouso;
2. calcular o valor RMS do sinal na janela de tempo processada (250 ms) e, posteriormente, calcular a razão entre este valor e o valor RMS do mesmo canal em repouso, obtido através do arquivo criado durante a calibração;
3. a janela é considerada válida, ou não, comparando o valor desta razão com um limiar baseado no RCR definido, igualmente, durante a calibração correspondente à razão entre o RMS de contração voluntária máxima (MVC) e de repouso.

Figura 22: Sinal do canal 1 antes e depois da segmentação.





Figura 23: Sinal do canal 7 antes e depois da segmentação.



O procedimento é descrito pelo código *MATLAB*:

```

% PARAMETERS
WINDOW_SIZE=249;
SERIE_MILLISECONDS=numel(SIGNAL);
RCR=RMS_MVC/RMS_RELAXED;

% SEGMENTATION
index=1;
while index+WINDOW_SIZE <= SERIE_MILLISECONDS
    SIGNAL_MOVEMENT=SIGNAL(index:index+WINDOW_SIZE,:);
    RMS=rms(SIGNAL_MOVEMENT);
    if((RMS/RMS_RELAXED) > (THRESHOLD*RCR))
        SIGNAL_SEG(index:index+WINDOW_SIZE,:)=SIGNAL_MOVEMENT;
    else
        SIGNAL_SEG(index:index+WINDOW_SIZE,:)=0;
    end
    index=index+(WINDOW_SIZE+1);
end

% REMAINING SIGNAL
SIGNAL_MOVEMENT=SIGNAL(index:SERIE_MILLISECONDS,:);
if(max(SIGNAL_MOVEMENT)>THRESHOLD)
    SIGNAL_SEG(index:SERIE_MILLISECONDS,:)=SIGNAL_MOVEMENT;
else
    SIGNAL_SEG(index:SERIE_MILLISECONDS,:)=0;
end

```


3.3.5 Extração de Características

Parâmetros ou métricas estatísticas (chamados de características) são utilizados para alimentar os métodos de regressão e aumentar a sua eficiência. A seleção de características eficazes é um dos estágios mais críticos no desenvolvimento e no gerenciamento de dispositivos com controle eletromiográfico. As características deste sinal dependem da duração da contração, do estado dinâmico ou estático do músculo, da fadiga, suor da pele etc.

As características temporais, baseadas na amplitude do sinal, são as mais populares na classificação mioelétrica graças a sua simplicidade computacional (OSKOEI & HU, 2007). A amplitude pode ser definida como a variação temporal do desvio padrão de um sinal. Este valor é influenciado por fatores tais como a localização do eletrodo, a espessura dos tecidos, a distribuição de unidades motoras em fibras musculares, as velocidades de condução do músculo, e o sistema de detecção utilizado para adquirir o sinal.

A fim de obter bons resultados de estimação usando métodos lineares a relação entre as características extraídas e a saída (dados que definirão o movimento) deve ser a mais linear possível. Por este motivo uma das características temporais utilizada neste estudo é o RMS. Ele é adquirido após a aplicação da transformação não linear $f(x) = \sqrt{x}$ à média aritmética dos quadrados dos valores de intensidade do sinal, como mostra a Equação (21). Além deste valor, a variância, desvio padrão e obliquidade, que caracteriza a forma do sinal, também fazem parte do leque de escolhas para alimentar o classificador (Equação (22), Equação (23) e Equação (24), respectivamente).

$$RMS = \sqrt{\frac{1}{N} \sum_{t=1}^N EMG(t)^2} \quad (21)$$

$$\Sigma^2 = \frac{1}{N-1} \sum_{t=1}^N (EMG(t) - \bar{X})^2 \quad (22)$$

$$\Sigma = \sqrt{\Sigma^2} \quad (23)$$

$$O = \sum_{t=1}^N \left(\frac{EMG(t) - \bar{X}}{\Sigma} \right)^3 * p(EMG(t)) \quad (24)$$

onde N é o número de amostras que compõem o sinal e \bar{X} a média do sinal.

Esta etapa final do pré-processamento é finalizada com o armazenamento dos resultados descritivos do sinal em um arquivo, exemplificado na Figura 24, que será

posteriormente lido pelo bloco de processamento a fim de modelar os dados através de regressão logística. O procedimento de geração dos valores característicos é descrito pelo código *MATLAB*:

```

% RMS
RMS=rms (MOVEMENT) ;

% STANDARD DEVIATION
STD=std (MOVEMENT) ;

% VARIANCE
VAR=var (MOVEMENT) ;

% SKEWNESS
SKEW=skewness (MOVEMENT) ;

```

Figura 24: Arquivo gerado após o bloco de extração de características.

RMS C0	STD C0	VAR C0	SKEW C0	RMS C1	STD C1	VAR C1	SKEW C1	
0.030523	0.030525	0.00093178	0.61918	0.011419	0.011419	0.0001304	0.58204	
0.0050789	0.0050791	2.5797e-05	0.22554	0.063631	0.063633	0.0040492	2.6024	
0.018376	0.018377	0.00033773	0.14103	0.014982	0.014983	0.00022449	0.72431	
0.10485	0.10485	0.010994	-0.17914	0.0090033	0.0090036	8.1065e-05	0.61626	
0.0047831	0.0047833	0,02288	0.17783	0.054844	0.054846	0.0030081	2.4454	...
0.011496	0.011497	0.00013218	0.12791	0.01238	0.01238	0.00015327	0.9118	
0.0031326	0.0031328	9.8146e-06	0.36084	0.024496	0.024498	0.00060015	0.28397	
0.0041422	0.0041424	0,01716	0.26181	0.065886	0.065889	0.0043414	2.0456	
0.0032018	0.003202	1.0253e-05	0.29809	0.02467	0.024672	0.0006087	0.14507	
0.0056259	0.0056261	3.1653e-05	-0.39697	0.029296	0.029297	0.00085829	0.32986	
								...

3.4 Processamento do sinal mioelétrico

A etapa de processamento deste experimento é responsável por reconhecer os padrões do sinal e, portanto, tomar as decisões finais sobre o gerenciamento do dispositivo. Devido à complexidade dos sinais biológicos, e a influência de condições físicas e fisiológicas, o algoritmo utilizado deve ser suficientemente robusto e inteligente, adaptando-se à mudanças através da exploração de treinamentos.

O aprendizado supervisionado é uma técnica de aprendizagem automática que utiliza dados de base para estimar regras e, portanto, prever resultados de novas entradas. Dentro deste ramo de algoritmos foi escolhida a regressão logística para validar o experimento.

A linguagem utilizada para implementar o classificador baseado em regressão logística foi *Python*. Esta linguagem oferece ferramentas simples e eficientes para a análise de dados como *NumPy*, *SciPy* e *Matplotlib*. Python é expressivo, com abstrações de alto nível. Isto também faz com que o ciclo de desenvolvimento seja rápido e apresente potencial de defeitos reduzido já que, menos código implica em menos oportunidade para errar.

3.4.1 Modelo de Regressão

O conjunto de vetores de C características de determinados canais para M observações/movimentos, capturados durante as séries de treinamento, é representado por $X \in \mathbb{R}^{M \times C}$. Os valores que compõem esta matriz são fornecidos pela etapa de extração de características, última fase do pré-processamento, que consiste na caracterização de segmentos do sinal que interpretam movimentos. O vetor $Y \in \mathbb{R}^{1 \times M}$ contém o identificador de cada um destes M movimentos de treinamento especificados por X . Sabendo que foram utilizados nove movimentos diferentes, apresentados na Seção 3.2.1.1, para compor as séries de ensaios pode-se afirmar que $Y = \{1, 2, 3, 4, 5, 6, 7, 8, 9\}$ ou, de forma equivalente, $Y = \{RA, FA, CM, FP, EP, RFA, CMF, EFP, RAC\}$ e, deste modo, é utilizado o método de tratamento de regressão multinomial.

A título de exemplo, a Figura 25, apresenta um arquivo de treinamento obtido após o pré-processamento de um ensaio da série 1, exposta na Tabela 4. Neste caso foram utilizados os valores de RMS, desvio padrão, variância e obliquidade de sete canais para descrever os movimentos, determinando, portanto, $X \in \mathbb{R}^{M \times 28}$. As primeiras 28 colunas representam a matriz X descrita na Figura 25 e a última coluna o vetor Y .

Figura 25: Exemplo de arquivo de treinamento contendo três canais e duas características por canal: RMS e desvio padrão.

RMS C0	STD C0	VAR C0	SKEW C0	RMS C1	STD C1	VAR C1	SKEW C1	MOV ID
0.030523	0.030525	0.00093178	0.61918	0.011419	0.011419	0.0001304	0.58204	1
0.0050789	0.0050791	2.5797e-05	0.22554	0.063631	0.063633	0.0040492	2.6024	8
0.018376	0.018377	0.00033773	0.14103	0.014982	0.014983	0.00022449	0.72431	2
0.10485	0.10485	0.010994	-0.17914	0.0090033	0.0090036	8.1065e-05	0.61626	6
0.0047831	0.0047833	0.02288	0.17783	0.054844	0.054846	0.0030081	2.4454	8
0.011496	0.011497	0.00013218	0.12791	0.01238	0.01238	0.00015327	0.9118	2
0.0031326	0.0031328	9.8146e-06	0.36084	0.024496	0.024498	0.00060015	0.28397	3
0.0041422	0.0041424	0.01716	0.26181	0.065886	0.065889	0.0043414	2.0456	4
0.0032018	0.003202	1.0253e-05	0.29809	0.02467	0.024672	0.0006087	0.14507	3
0.0056259	0.0056261	3.1653e-05	-0.39697	0.029296	0.029297	0.00085829	0.32986	7
...								

X
 Y

3.4.3 Treinamento

A capacidade de generalização e desempenho do modelo apresentado é realizada a partir de um conjunto de dados. Esta base de informação é dividida em conjuntos de treinamento e conjuntos de teste. Geralmente, quanto maior o arquivo de treinamento melhor o classificador, e quanto maior o arquivo de teste mais exata será a estimativa de erro.

O algoritmo de indução de conhecimento é aplicado à base de treinamento obtendo um modelo inteligente e, este, por sua vez, é aplicado a base de testes. Uma vez que a base de testes é previamente rotulada, é possível medir a taxa de acerto do modelo comparando o resultado previsto pelo classificador com a rotulação real.

3.5 Ensaios e Indivíduos

Os resultados dos ensaios realizados neste estudo consistem na exposição lógica e reflexiva dos métodos e conceitos apresentados nas seções anteriores através da interpretação e julgamento rigoroso dos dados recolhidos. A Figura 26 expõe todos os elementos envolvidos em um ensaio de aquisição de sinais, onde percebe-se a voluntária seguindo os movimentos ditados pelo vídeo ao passo que seus sinais mioelétricos são captados pelos eletrodos conectados ao eletromiógrafo, que por sua vez está conectado a placa de aquisição diretamente ligada ao computador e fornecendo as informações necessárias ao programa de aquisição.

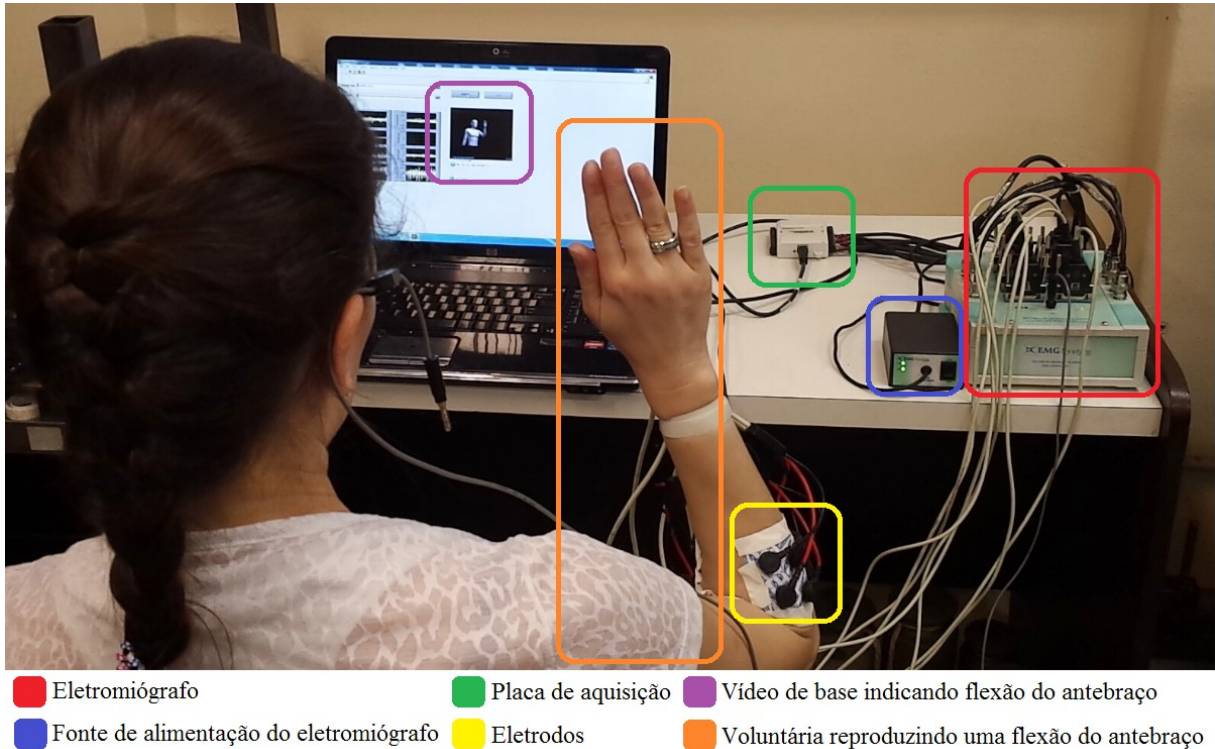
A base de dados deste trabalho foi formada por cinco voluntários com idade média de 23 anos e desvio padrão de 1.01. Todos os envolvidos foram esclarecidos sobre o experimento e assinaram o Termo de Livre Consentimento referente ao projeto aprovado pelo Comitê de Ética.

Para cada um dos ensaios efetuados as seguintes etapas foram repetidas:

1. Assinatura do Termo de Livre Consentimento;
2. Identificação dos músculos e posicionamento dos eletrodos;
3. Conexão dos eletrodos ao eletromiógrafo através de cabos;
4. Calibração e possíveis reposicionamentos de eletrodos;
5. Aquisição dos sinais;
6. Pré-processamento dos sinais adquiridos;
7. Processamento dos sinais adquiridos;
8. Análise dos resultados.

Os passos citados anteriormente foram reproduzidos sequencialmente e, portanto, caracterizam uma exposição *offline*. Isto é, a etapa da aquisição é finalizada antes que o pré-processamento e processamento dos sinais sejam realizados.

Figura 26: Ensaio com a Voluntária 5.



3.5.1 Posicionamento dos Eletrodos

Os eletrodos, elementos responsáveis por captar a atividade muscular, foram posicionados em sete músculos diferentes para todos os ensaios realizados. A Tabela 5 lista os músculos e respectivos canais aos quais os eletrodos foram conectados ao eletromiógrafo.

Tabela 5: Associação de canais e músculos.

Canal	Músculos
0	Bíceps braquial
1	Flexor radial do carpo
2	Flexor ulnar do carpo
3	Extensor dos dedos

Continuação da Tabela 5.

4	Pronador Redondo
6	Palmar longo
7	Extensor ulnar do carpo

A Figura 27 e a Figura 28 mostram um dos indivíduos voluntários com os eletrodos posicionados corretamente, após a etapa de calibração do sistema.

Figura 27: Posicionamento dos eletrodos dos canais 0, 1, 4 e 6.

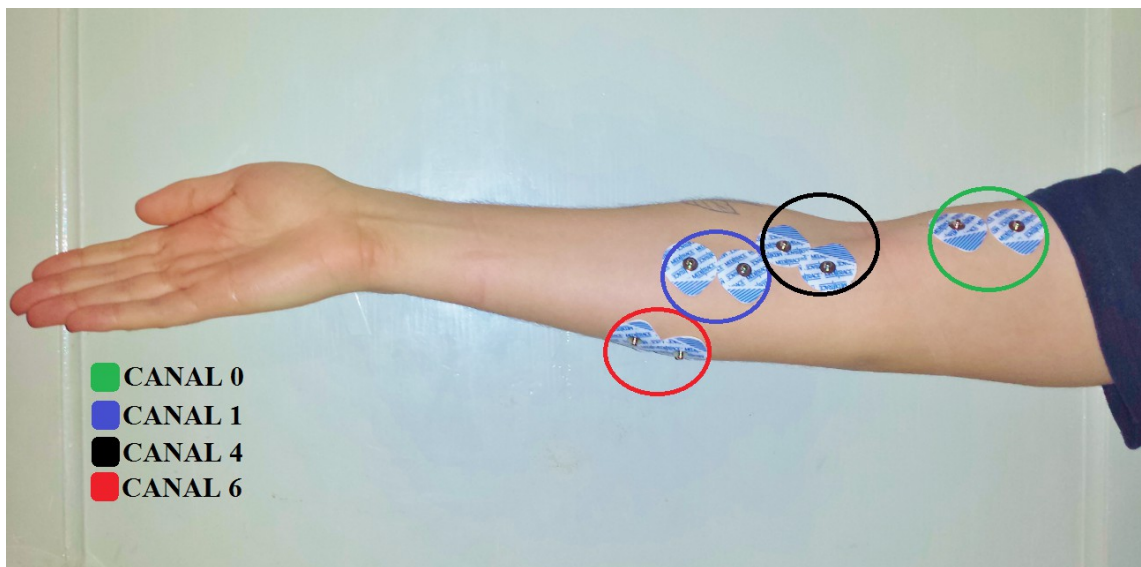



Figura 28: Posicionamento dos eletrodos dos canais 2, 3, 6 e 7.



3.5.2 Testes e Resultados

A fim de explorar as possibilidades e limites da etapa de processamento foram realizadas diversas configurações de teste, variando o número de canais e as características utilizadas, assim como, a disposição dos dados de treinamento e teste.

3.5.2.1 Taxa de acerto

Para comparar os resultados de diferentes arranjos é calculada uma taxa de acerto, exposta pela Equação (25), que descreve a porcentagem de movimentos que foram corretamente preditos pelo classificador com determinada configuração.

$$\text{Taxa de acerto geral} = \frac{\# \text{Verdadeiros Positivos}}{\# \text{Movimentos}} \quad (25)$$

Chama-se de Verdadeiro Positivo um bom diagnóstico feito pelo classificador, isto é, caso o conjunto de características descreva o movimento k , e, o classificador indica, corretamente, uma saída k é dito que ocorreu um Verdadeiro Positivo. Para entender melhor o modelo e encontrar as dificuldades enfrentadas pelo classificador também é calculada a taxa de acerto para cada um dos nove movimentos reproduzidos durante os ensaios e que, é descrita pela Equação (26).

$$\text{Taxa de acerto por movimento } k = \frac{\# \text{Verdadeiros Positivos } k}{\# \text{Movimentos } k} \quad (26)$$


Além do Verdadeiro Positivo existem outros termos utilizados durante a análise de previsão dos arranjos de teste:

- Verdadeiro Negativo: quando o exemplo não pertence à determinada classe e o classificador prediz, corretamente, que o exemplo não pertence à classe;
- Falso Positivo: quando o exemplo não pertence à determinada classe e o classificador prediz que o exemplo pertence à classe;
- Falso Negativo: quando o exemplo pertence à determinada classe e o classificador prediz que o exemplo não pertence à classe.

3.5.2.2 Parâmetro regulador

Os resultados de cada um dos arranjos de teste é apresentado graficamente através de sua variação percentual de acertos em relação ao aumento do fator regulador na função de custo. Na Seção 2.6.4 foi mencionado que a adição de um fator λ na função custo é capaz de penalizar a escolha de valores altos como parâmetros, o que, na verdade, pode ser traduzido por uma penalização pela complexidade assumida pelo modelo. Quanto menor for este parâmetro mais complexo é o modelo e vice-versa. A Figura 29 mostra o caso simplificado de um classificador com apenas duas classes e o efeito sobre a fronteira de decisão com o aumento do parâmetro regulador.

Figura 29: Relação entre o aumento do parâmetro regulador e a diminuição da complexidade do modelo.

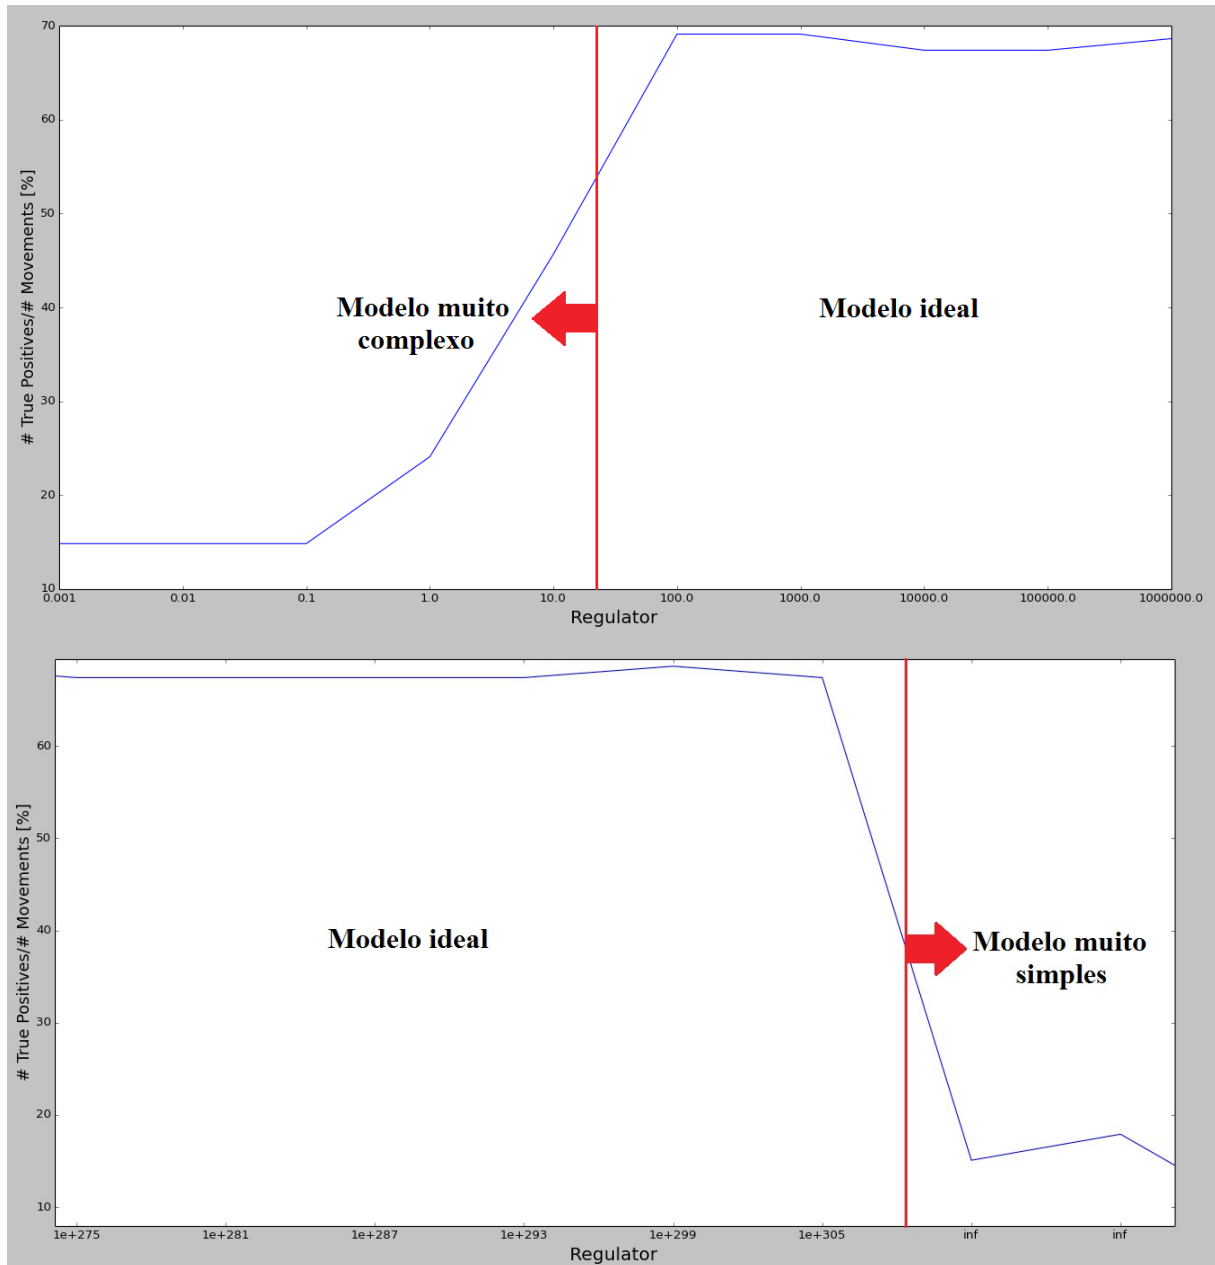


Não é suficiente para um algoritmo de aprendizado otimizar a função custo para o conjunto de treinamento, é necessário que ele seja mais abrangente. Caso ele não funcione adequadamente com novos dados, por exemplo os de teste, é dito que o algoritmo está *overfitted*, ou seja, que a regra é tão complexa que só funciona para o conjunto com o qual o classificador foi treinado. Caso ele não funcione adequadamente nem mesmo para o conjunto de treinamento, é dito que o algoritmo está *underfitted*, isto é, a regra é muito simples. O parâmetro de regularização é, então, responsável por encontrar um compromisso entre os dois extremos.

O gráfico exibido na Figura 30 descreve os resultados do classificador, a taxa de acerto geral, aplicado a um conjunto de dados de verificação. Nele pode-se observar que, para um regulador pequeno, ou seja, um modelo bastante complexo, são obtidas baixas taxas de acerto já que, ele é adaptado somente ao conjunto de treinamento. Ao aumentar o regulador e,

por conseguinte, diminuir a complexidade do modelo são obtidas melhores taxas até o caso limite de assumir um modelo extremamente simples que não é capaz de descrever corretamente as sutilezas necessárias ao classificador.

Figura 30: Desempenho de um modelo aplicado ao conjunto de teste.



3.5.2.3 Casos de teste

A variação das características utilizadas para descrever os sinais correspondentes aos movimentos revela quais informações têm maior relevância e como a combinação delas pode contribuir para um melhor resultado do modelo. Por exemplo as características reveladas pela

variância podem ser complementares àquelas reveladas pelo desvio padrão e, portanto, quando utilizadas em conjunto, essas características são capazes de determinar o sinal de um movimento. Os testes foram feitos inicialmente descrevendo os sinais através apenas de cada uma das características, individualmente, e depois foram testadas algumas combinações possíveis.

A fim de analisar a influência dos músculos/canais sobre a caracterização dos movimentos, inicialmente, utilizou-se apenas o canal 1 e, incrementalmente, os outros canais foram adicionados. Através da melhoria observada ao considerar determinado canal pode-se concluir quais canais foram chaves na contribuição de um melhor resultado do classificador e, portanto, diminuir o número de canais e, ainda assim, obter bons resultados.

A última variação realizada visa mostrar a influência da escolha dos conjuntos de teste e treinamento sobre o resultado. É intuitivo imaginar que, uma vez que a base de treinamento é pequena, poucos exemplos alimentam o classificador e, portanto, o modelo é bastante restrito. Desta forma o resultado esperado para o conjunto testado não é bom. O modelo ideal é criado a partir de um conjunto de treinamento abrangente o suficiente que, independente do conjunto de teste, apresentará bons resultados.

Os conjuntos de teste e treinamento foram criados de forma aleatória apenas impondo uma restrição sobre a porcentagem de dados do conjunto completo com a qual seriam compostos e, uma imposição que garante uma distribuição igual sobre a quantidade de exemplos de cada tipo de movimento considerado. Por exemplo ao impor a restrição de construção de um conjunto de teste formado por 20% dos dados de uma base de dados com 118 movimentos, como é o caso do Voluntário 2, obtém-se um subconjunto com 23 resultados ($118 * 0.2 \approx 23$). Pelo fato de existir este arredondamento, a maioria dos conjuntos são formados por uma porcentagem não exata, neste caso por exemplo, apesar de ter sido imposta a condição de 20% o subconjunto final é formado por 19.5% dos dados do conjunto completo ($23/118 = 0.1949 \approx 0.2$). Além disto, para este caso, a descrição dos 23 movimentos que compõem o subconjunto são distribuídos entre as 9 categorias possíveis, contendo em alguns casos 2 exemplos e, em outros 3 de cada movimento ($23/9 = 2.55$).

4 RESULTADOS E DISCUSSÕES

A avaliação dos resultados alcançados para diferentes métodos de caracterização do sinal mioelétrico através de regressão logística possibilita o entendimento e comprovação do desempenho deste método. Os casos de teste explorados foram escolhidos de forma a estender o estudo do efeito das decisões feitas pelo classificador e comprovar sua forma de funcionamento.

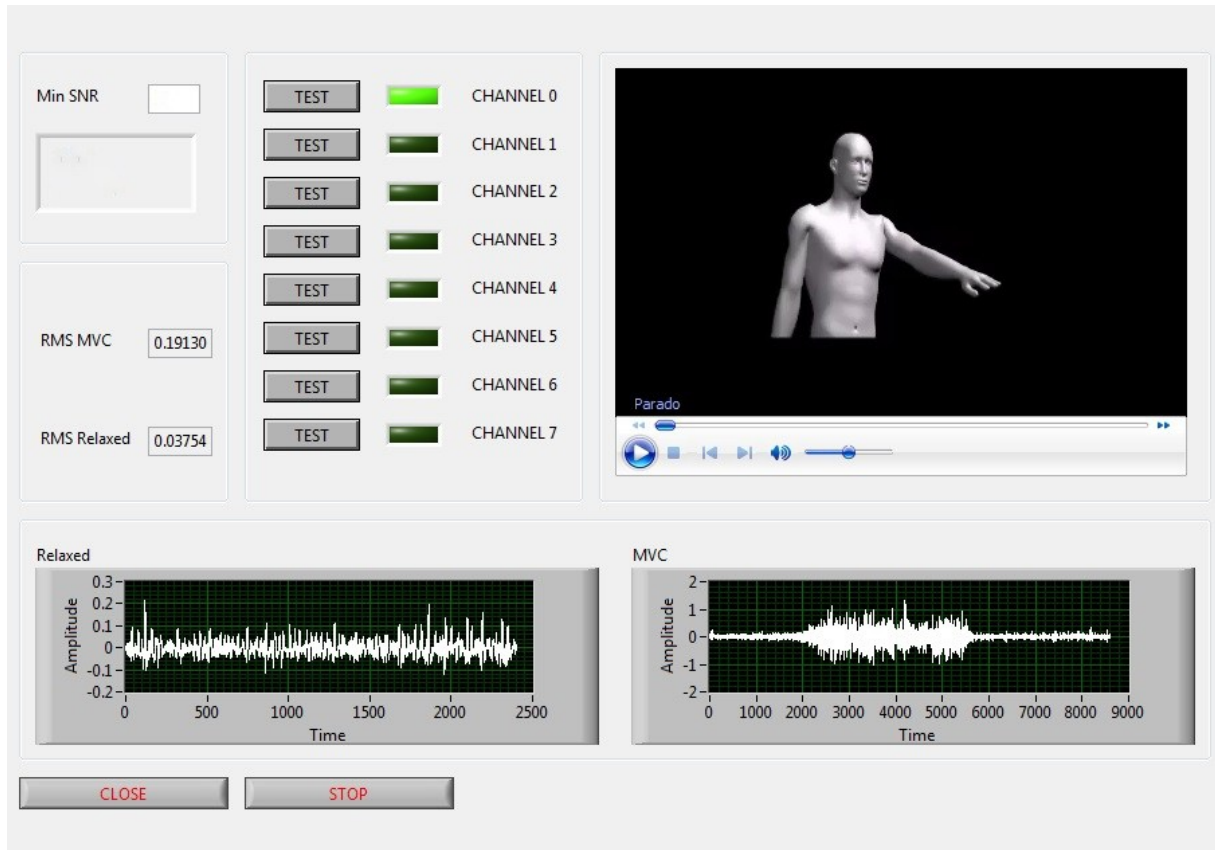
4.1 Voluntário 1

O Voluntário 1 efetuou três ensaios produzindo um banco de dados com um total de 432 movimentos rotulados e, especificados na Tabela 6. A Figura 31 apresenta, como exemplo, a calibração do canal utilizado durante os ensaios para capturar os sinais produzidos pelo bíceps braquial. A calibração dos demais canais é apresentada no APÊNDICE – calibração do Voluntário 1.

Tabela 6: Movimentos realizados pelo Voluntário 1.

Movimento	[rótulo]	Repetições
Rotação do Antebraço	[1]	48
Flexão do Antebraço	[2]	48
Contração da Mão	[3]	48
Flexão do Punho	[4]	48
Extensão do Punho	[5]	48
Rotação e Flexão do Antebraço	[6]	48
Contração da Mão e Flexão do antebraço	[7]	48
Extensão e Flexão do Punho	[8]	48
Rotação do Antebraço e Contração da mão	[9]	48
Total de movimentos		432

Figura 31: Calibração do canal referente ao bíceps braquial.



4.1.1 Variação de características utilizadas

Os resultados apresentados a seguir foram alcançados utilizando os sinais de todos os sete canais através dos quais os dados foram adquiridos. Foi usado um conjunto de dados de teste com 17.8% da base total com 432 observações e, um conjunto de treinamento formado pelos dados restantes. A Tabela 7 mostra a distribuição dos movimentos deste conjunto de verificação.

Tabela 7: Distribuição dos movimentos que formam a base de dados de teste usados na Seção 4.1.1.

Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Total
Repetições	10	7	10	7	10	10	8	5	10	77

4.1.1.1 RMS

A caracterização dos movimentos através apenas do valor RMS, dos sinais advindos dos sete canais de aquisição, foi capaz de produzir, para este indivíduo e movimentos de teste,

uma taxa de acerto geral de 96.1% para o parâmetro regulador $\lambda=10^{11}$, como mostra a Figura 32. A Tabela 8 revela quais movimentos o algoritmo tem maior dificuldade de prever corretamente. É apurado que os movimentos RA, EFP e RAC possuem os piores desempenhos, sendo devidamente classificados em 90%, 80% e 90% dos casos, respectivamente.

Figura 32: Resultados do Voluntário 1 usando apenas RMS para caracterizar os sete canais de aquisição.




Tabela 8: Taxa de acerto para melhor escolha de parâmetro regulador do modelo.

Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Geral
Taxa de acerto %	90	100	100	100	100	100	100	80	90	96.1

Analisando a Tabela 9, que mostra como cada movimento (um por linha) foi categorizados (colunas), é possível averiguar que os movimentos RA e RAC confundem-se entre si nos únicos casos em que foram mal categorizados. O outro caso prejudicial à taxa de acerto ocorreu na detecção equivocada do movimento EFP como EP. Novamente, o Falso Positivo ocorre entre um movimento composto e um de seus movimentos simples originários.

Tabela 9: Matriz de decisão do classificador frente a cada categoria de movimento.

	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Total
RA	9	0	0	0	0	0	0	0	1	10
FA	0	7	0	0	0	0	0	0	0	7
CM	0	0	10	0	0	0	0	0	0	10
FP	0	0	0	7	0	0	0	0	0	7
EP	0	0	0	0	10	0	0	0	0	10
RAF	0	0	0	0	0	10	0	0	0	10
CMF	0	0	0	0	0	0	8	0	0	8
EFP	0	0	0	0	1	0	0	4	0	5
RAC	1	0	0	0	0	0	0	0	9	10

4.1.1.2 RMS, desvio padrão, variância e obliquidade

Ao implementar a descrição dos movimentos através apenas de uma das características apresentadas na Seção 3.3.5, individualmente, foram obtidos os resultados expostos na Figura 33. Portanto, os dois valores que melhor descrevem um sinal mioelétrico do conjunto de dados do Voluntário 1 são os valores RMS e desvio padrão, capazes de prever corretamente 96.1% das observações.

Figura 33: Desempenho do classificador para descrição dos dados do Voluntário 1 através de cada característica individualmente.

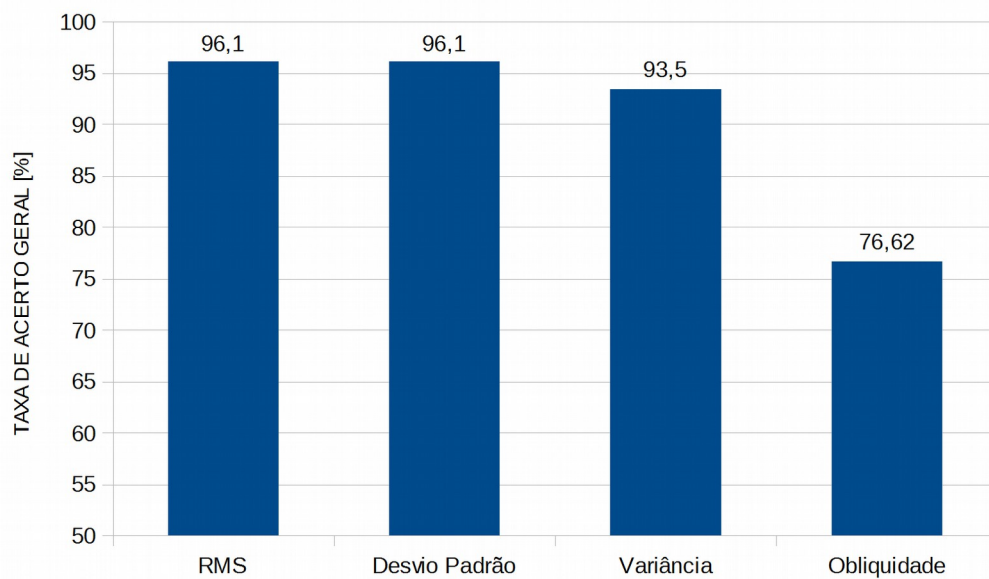



Figura 34: Resultados do Voluntário 1 usando RMS, desvio padrão, variância e obliquidade em conjunto para caracterizar os sete canais de aquisição.



A melhoria de 2.1% no desempenho do classificador, que usa 4 características de 7 canais para tomar decisões, representa o *trade-off* entre o volume de dados processados e a melhoria no desempenho. Neste caso, foram usadas 28 variáveis independentes para descrever um movimento, ao contrário da Seção 4.1.1.1, que usou apenas 7 variáveis. Este aumento de 300% no volume de dados envolvidos na tomada de decisão do classificador representou um aumento de apenas 2.1% na taxa de acerto geral.

4.1.2 Variação do número de canais utilizados

Utilizando novamente a configuração da Seção 4.1.1.1, que descreve os movimentos através apenas do valor RMS, é apresentada por meio da Figura 35 o desempenho do algoritmo com a variação do número de canais utilizados. A diminuição do número de canais implica na redução da quantidade de dados que definem a decisão do algoritmo e do número de eletrodos necessários, facilitando o uso deste tipo de método em sistemas de reabilitação como por exemplo, em próteses.


A Figura 35 revela que a melhoria mais significativa ocorre quando o canal zero e o canal três passam a ser considerados. Por esta razão é apresentado a seguir os resultados detalhados do uso de apenas dois canais, o canal zero e canal três, para especificar os gestos.

A Tabela 12 evidencia o sucesso do algoritmo em 85.7% dos casos testados, ou seja, uma diminuição de 14.3% do desempenho em relação ao uso dos sete canais originais.

Tabela 12: Taxa de acerto dos movimentos e taxa de acerto geral.

Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Geral
Taxa de acerto %	70	85.7	70	100	80	100	100	80	90	85.7

Figura 35: Desempenho do classificador X Canais para o Voluntário 1.



Ao considerar apenas os canais zero e três a taxa de acerto geral é bastante afetada em relação à desempenho de 96.1%, quando todos os canais são considerados. A Tabela 13 aponta que, mesmo com o uso de apenas dois canais, os erros continuam ocorrendo entre gestos ligados por movimentos simples comuns, como por exemplo, a má identificação do EP como EFP duas vezes.

Tabela 13: Matriz de decisão do classificador frente a cada categoria de movimento.

	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Total
RA	7	1	0	0	0	1	0	0	1	10
FA	0	6	0	0	0	0	1	0	0	7
CM	0	0	7	0	2	0	0	1	0	10
FP	0	0	0	7	0	0	0	0	0	7

Continuação da Tabela 13.

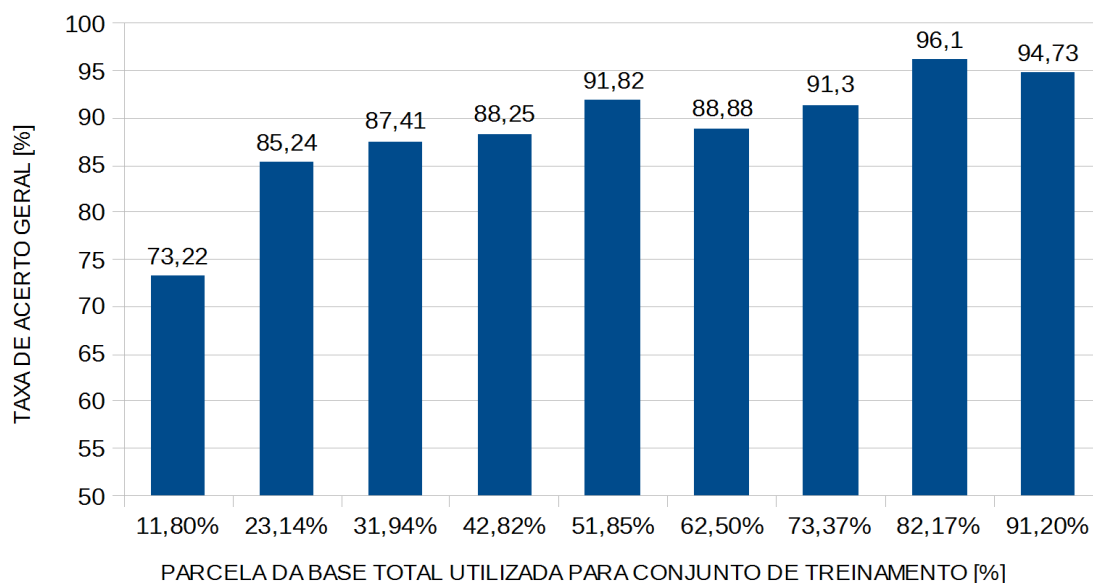
EP	0	0	0	0	8	0	0	2	0	10
RAF	0	0	0	0	0	10	0	0	0	10
CMF	0	0	0	0	0	0	8	0	0	8
EFP	0	0	0	0	1	0	0	4	0	5
RAC	1	0	0	0	0	0	0	0	9	10

4.1.3 Variação do tamanho do conjunto de treinamento

Os números apresentados a seguir são produto do arranjo de teste formado por dimensões variáveis das bases de teste e treinamento descritas pelo valor RMS dos sete canais adquiridos durante os ensaios, semelhante à Seção 4.1.1.1.

Sabendo que a constituição das bases de teste e treinamento é feita aleatoriamente a partir da restrição sobre a porcentagem de dados que deve ser atribuída a cada uma delas e, que existem movimentos mais facilmente identificados do que outros, há casos em que, mesmo aumentando a base de treinamento, uma diminuição na taxa de acerto geral é observada. Entretanto, de modo geral, como já explicado na Seção 3.4.3, ao ampliar a base de treinamento o classificador torna-se cada vez mais apto a capturar as particularidades necessárias ao seu bom desempenho. Este aspecto é constatado no gráfico exibido na Figura 36 onde, via de regra, a taxa de acerto geral aumenta com as dimensões da base de treinamento.

Figura 36: Parcela da base total utilizada para o conjunto de treinamento X taxa de acerto geral para o Voluntário 1.



A Tabela 14 exalta as proporções utilizadas para compor as bases de teste e treinamento a partir do conjunto completo de 432 movimentos. O melhor resultado foi alcançado pela formação de um conjunto de treinamento com 355 movimentos onde foram testados 77 movimentos e 74 deles foram corretamente classificados, ou seja, obteve-se sucesso em 96.1% dos casos. Já, o pior resultado ocorreu para o modelo criado a partir de uma base de treinamento de apenas 51 movimentos testados em 381 movimentos diferentes. Destes 381 gestos testados 279 foram corretamente identificados.

Tabela 14: Detalhamento dos casos de teste variando as dimensões do conjunto de dados de teste e treinamento.

	11.80%	23.14%	31.94%	42.82%	51.85%	62.50%	73.37%	82.17%	91.20%
Teste	381	332	294	247	208	162	115	77	38
Trein.	51	100	138	185	224	270	317	355	394
Total	432	432	432	432	432	432	432	432	432

4.2 Voluntário 2

O Voluntário 2 realizou um ensaio produzindo uma base de dados com um total de 108 movimentos rotulados e, especificados pela Tabela 15. A Figura 37 expõe a calibração do canal utilizado durante os ensaios para capturar os sinais produzidos pelo bíceps braquial. A calibração dos demais canais é apresentada no APÊNDICE – calibração do Voluntário 2.

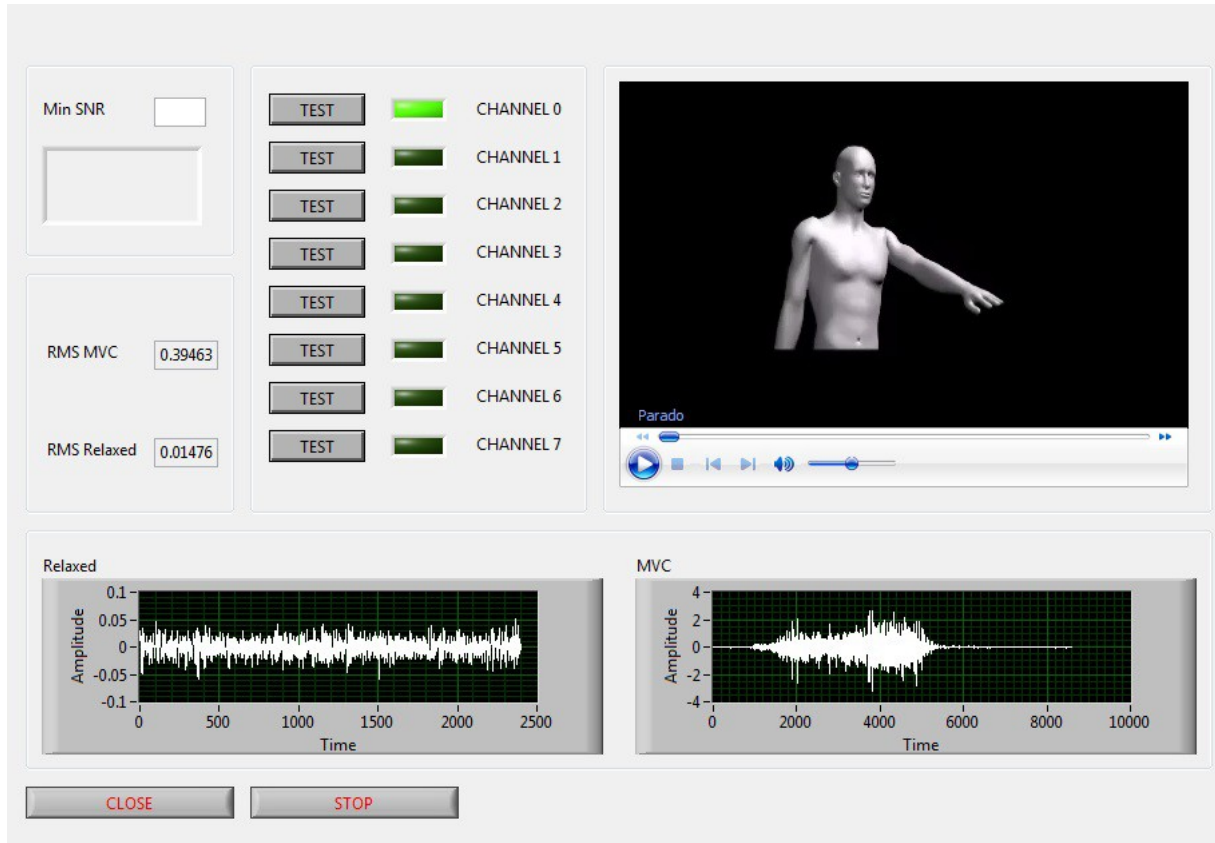
Tabela 15: Distribuição dos movimentos realizados pelo Voluntário 2 durante o ensaio.

Movimento	[rótulo]	Repetições
Rotação do Antebraço	[1]	12
Flexão do Antebraço	[2]	12
Contração da Mão	[3]	12
Flexão do Punho	[4]	12
Extensão do Punho	[5]	12
Rotação e Flexão do Antebraço	[6]	12
Contração da Mão e Flexão do antebraço	[7]	12
Extensão e Flexão do Punho	[8]	12

Continuação da Tabela 15.

Rotação do Antebraço e Contração da mão[9]	12
Total de movimentos	108

Figura 37: Calibração do canal 0 referente ao bíceps braquial.




4.2.1 Variação de características utilizadas

Os resultados apresentados a seguir foram alcançados utilizando informações de todos os sete canais através dos quais os dados foram adquiridos. Foi usado um conjunto de dados de teste com 13% da base total com 108 observações e, um conjunto de treinamento com os dados restantes. A Tabela 16 mostra a distribuição dos movimentos neste conjunto de dados de verificação.

Tabela 16: Distribuição dos movimentos que formam a base de dados de teste usados na Seção 4.2.1.

Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Total
Repetições	2	1	2	1	1	2	2	2	2	15

Figura 38: Resultados do Voluntário 2 usando apenas RMS para caracterizar os sete canais de aquisição.



4.2.1.2 RMS, Desvio Padrão, Variância e Obliquidade

Mais uma vez é utilizado, para este caso, todos os setes canais da configuração de base de teste e treinamento apresentada na Seção 4.2.1.1. Contudo, a caracterização do sinal é feita através, não somente do valor RMS, mas também do desvio padrão, variância e obliquidade. Segundo a Figura 39 estas características, quando testadas individualmente, apresentam resultados idênticos, classificando corretamente 93.3% dos gestos testados.

Pelo fato das características não serem capazes de salientar peculiaridades diferentes em relação a cada movimento, para este indivíduo, o resultado final apresentado pelo classificador que utiliza estas características em conjunto para descrever um gesto, mantém o resultado geral de 93.3%. Este desempenho é detalhado na Seção 4.2.1.1 pela Tabela 17 e pela Tabela 18, e comprovado pela Figura 40.

Figura 39: Desempenho do classificador para descrição dos dados do Voluntário 2 através de cada característica individualmente.





Figura 40: Resultados do Voluntário 2 usando RMS, desvio padrão, variância e obliquidade em conjunto para caracterizar os sete canais de aquisição.




4.2.2 Variação do número de canais utilizados

Mantendo a configuração de base de teste e treinamento da Seção 4.2.1.1, utilizando apenas o valor RMS para caracterizar os sinais adquiridos, os resultados apresentados a seguir exploram a influência dos canais sobre as decisões do classificador. A Figura 41 comprova a


relação proporcional entre o aumento do número de canais que descrevem um movimento e o desempenho obtido. O único canal que foge a esta regra é o canal dois, este comportamento pode ser explicado por anomalias capturadas durante os ensaios como ruído excessivo e descolamento do eletrodo. Além disto ao adicionar o canal sete não há melhoria do desempenho e, portanto, este canal pode ser desconsiderado a fim de aliviar a quantidade de informações processadas pelo algoritmo de decisão.

Figura 41: Desempenho do classificador X Canais para o Voluntário 2.



O auge do desempenho do classificador aplicado aos dados do Voluntário 2, identificando, corretamente, 100% dos movimentos testados, foi obtida eliminando os valores capturados pelos canais dois e sete para o parâmetro regulador $\lambda = 10^{11}$, conforme mostra a Figura 42.

Figura 42: Desempenho do classificador para a caracterização do sinal através do valor RMS de apenas cinco canais de aquisição do Voluntário 2.




4.2.3 Variação do tamanho do conjunto de treinamento

Os números apresentados a seguir são produto do arranjo de teste formado por dimensões variáveis das bases de teste e treinamento descritas pelo valor RMS dos sete canais adquiridos durante os ensaios, semelhante à Seção 4.2.1.1.

Sabendo que a constituição das bases de teste e treinamento é feita aleatoriamente a partir da restrição sobre a porcentagem de dados que deve ser atribuída a cada uma delas e, que existem movimentos mais facilmente identificados do que outros, há casos em que, mesmo aumentando a base de treinamento, uma diminuição na taxa de acerto geral é observada. Entretanto, de modo geral, como já explicado na Seção 3.4.3, ao ampliar a base de treinamento o classificador torna-se cada vez mais apto a capturar as particularidades necessárias ao seu bom desempenho. Este aspecto é constatado no gráfico exibido na Figura 43 onde, via de regra, a taxa de acerto geral aumenta com as dimensões da base de treinamento.

Figura 43: Parcela da base total utilizada para o conjunto de treinamento X taxa de acerto geral para o Voluntário 2.



Para entender melhor este comportamento é feita a comparação entre os casos onde a base de treinamento é formada por 63% e 73.1% dos movimentos realizados pelo Voluntário 2. A expectativa para a base de treinamento com 73.1% dos movimentos é melhor do que a com 63% dos movimentos pois, entende-se que, quanto mais alimenta-se um classificador maior a generalização do modelo e, portanto, melhor o desempenho. Entretanto, os movimentos escolhidos para cobrir as particularidades não capturadas pelo conjunto com 63% dos movimentos não foram suficientes. Desta forma os erros se repetiram, como mostra a Tabela 19, porém, em uma base de teste menor e que, portanto, tem sua taxa de acerto mais afetada a cada falha.

Tabela 19: Taxa de acerto dos movimentos para as bases de treinamento formadas por 62.96 e 73.1% do conjunto total de observações.

	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC
62.96%	80	100	100	80	100	80	100	100	33.3
73.14%	75	100	100	75	100	66.6	75	100	33.3

4.3 Voluntário 3

O Voluntário 3 realizou um ensaio produzindo uma base de dados com um total de 214 movimentos rotulados, especificados pela Tabela 20.

Tabela 20: Distribuição dos movimentos realizados pelo Voluntário 3.

Movimento	[rótulo]	Repetições
Rotação do Antebraço	[1]	24
Flexão do Antebraço	[2]	23
Contração da Mão	[3]	24
Flexão do Punho	[4]	24
Extensão do Punho	[5]	23
Rotação e Flexão do Antebraço	[6]	24
Contração da Mão e Flexão do antebraço	[7]	24
Extensão e Flexão do Punho	[8]	24
Rotação do Antebraço e Contração da mão	[9]	24
Total de movimentos		214

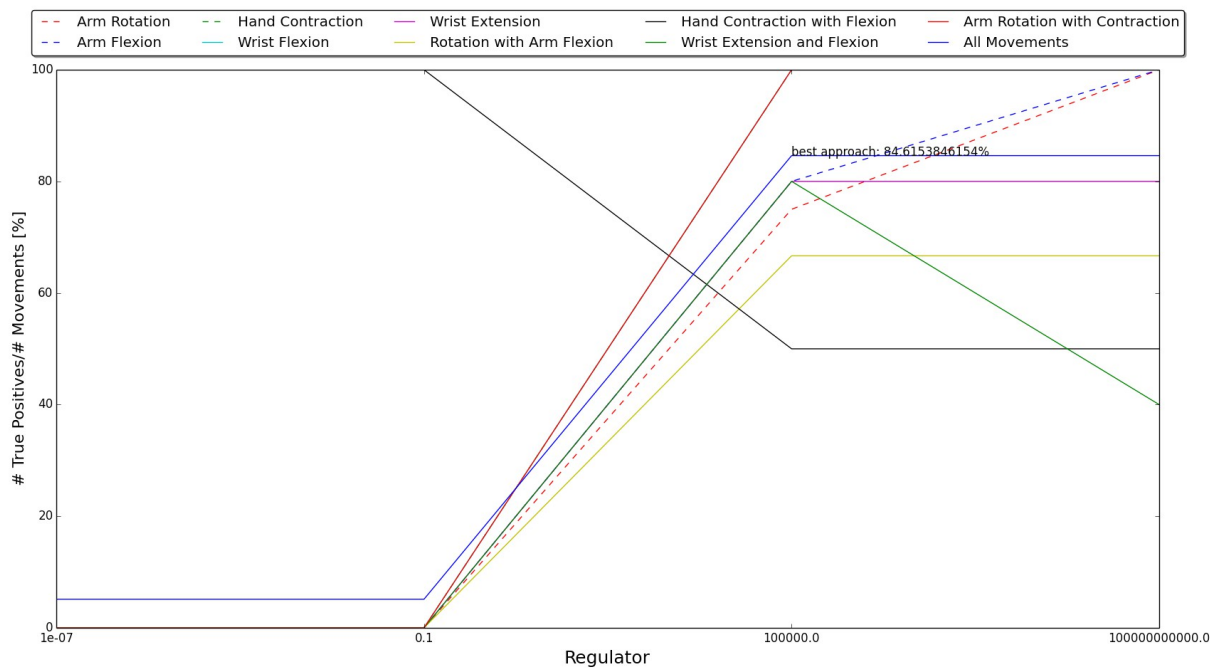
4.3.1 Variação de características utilizadas

Os resultados apresentados a seguir foram alcançados utilizando informações de todos os sete canais através dos quais os dados foram adquiridos. Foi usado um conjunto de dados de teste com 18.2% da base total formada por 214 movimentos e, um conjunto de treinamento com os dados restantes. A Tabela 21 mostra a distribuição dos movimentos nesta base de teste.

Tabela 21: Distribuição dos movimentos que formam a base de dados de teste usados na Seção 4.3.1.

Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Total
Repetições	4	5	5	5	5	3	2	5	5	39


Figura 44: Resultados do Voluntário 3 usando apenas RMS para caracterizar os sete canais de aquisição.



4.3.1.2 RMS e Desvio Padrão

Mais uma vez é utilizado, para este caso, todos os setes canais da configuração de base de teste e treinamento apresentada na Seção 4.3.1. Contudo, a caracterização do sinal é feita através, não somente do valor RMS, mas também do desvio padrão. Estas características foram estrategicamente escolhidas pois obtiveram o melhor desempenho quando testadas individualmente, como mostra o gráfico exposto na Figura 45.

Figura 45: Desempenho do classificador para descrição dos dados do Voluntário 3 através de cada característica individualmente.



Ao caracterizar o sinal através da combinação dos valores RMS e desvio padrão, a taxa de acerto ampliou para 87.2% com o parâmetro regulador $\lambda=10^5$, como mostra a Figura 46. Ao analisar a Tabela 24, que descreve a taxa de acerto para cada movimento, é percebido que este aperfeiçoamento foi possível graças a melhor caracterização, principalmente, do movimento de EFP, que passou a ter uma taxa individual de acerto de 80% ao contrário dos 40% no caso apresentado na Seção 4.3.1.1.

Figura 46: Resultados do Voluntário 3 usando RMS e desvio padrão em conjunto para caracterizar os sete canais de aquisição.




Tabela 24: Taxa de acerto dos movimentos e taxa de acerto geral.

Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Geral
Taxa de acerto %	75	100	100	100	80	66.6	50	80	100	87.2

A Tabela 25, além de apresentar erros gerados entre movimentos simples e compostos descendentes, também expõe a má classificação do movimento de RA como FA. Este equívoco é explicado pelo fato de ambos os movimentos terem como músculo ativador principal o bíceps braquial, como é revelado na Tabela 3, e, portanto, são mais facilmente confundidos.

Tabela 25: Matriz de decisão do classificador frente a cada categoria de movimento.

	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Geral
RA	3	1	0	0	0	0	0	0	0	4
FA	0	5	0	0	0	0	0	0	0	5
CM	0	0	5	0	0	0	0	0	0	5
FP	0	0	0	5	0	0	0	0	0	5
EP	0	0	0	0	4	0	0	1	0	5
RAF	1	0	0	0	0	2	0	0	0	3
CMF	0	0	1	0	0	0	1	0	0	2
EFP	0	0	0	1	0	0	0	4	0	5
RAC	0	0	0	0	0	0	0	0	5	5


4.3.2 Variação do número de canais utilizados

Mantendo a configuração de base de teste e treinamento da Seção 4.3.1.1, utilizando apenas o valor RMS para caracterizar os sinais adquiridos, os resultados apresentados a seguir exploram a influência dos canais sobre as decisões do classificador. A Figura 47 comprova a relação proporcional entre o aumento do número de canais que descrevem um movimento e o desempenho obtido.

É possível perceber, através desta mesma figura, que os canais dois e quatro, ao serem considerados, não acrescentam significativamente à melhoria da eficiência do algoritmo. Estes canais referem-se, respectivamente, ao flexor ulnar do carpo e ao pronador redondo. Com o objetivo de diminuir a quantidade de canais e, por conseguinte, a quantidade de

eletrodos necessários para desenvolver o projeto, os canais mencionados foram desconsiderados e os resultados avaliados.

Figura 47: Desempenho do classificador X Canais para o Voluntário 3.



A Tabela 26 e a Figura 48 revelam a conservação da taxa de acerto geral de 84.6% alcançado na Seção 4.3.1.1 mesmo desconsiderando dois canais e, portanto, diminuindo em 28.6% o volume de dados necessários para descrever as observações.

Tabela 26: Taxa de acerto dos movimentos e taxa de acerto geral.


Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Geral
Taxa de acerto %	75	100	80	100	80	66.6	50	80	100	84.6

Segundo a Tabela 3, os movimentos afetados pela desconsideração dos canais dois e quatro são os movimentos que contém, respectivamente, a rotação do antebraço e a flexão do punho. A Tabela 26 e a Tabela 27 mostra que a identificação, justamente, destes movimentos é prejudicial ao desempenho do algoritmo.

Tabela 27: Matriz de decisão do classificador frente a cada categoria de movimento.

	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Geral
RA	3	1	0	0	0	0	0	0	0	4
FA	0	5	0	0	0	0	0	0	0	5
CM	0	0	4	0	0	0	1	0	0	5
FP	0	0	0	5	0	0	0	0	0	5
EP	0	0	0	0	4	0	0	1	0	5
RAF	1	0	0	0	0	2	0	0	0	3
CMF	0	0	1	0	0	0	1	0	0	2
EFP	0	0	0	1	0	0	0	4	0	5
RAC	0	0	0	0	0	0	0	0	5	5

Figura 48: Desempenho do classificar para a caracterização do sinal através do valor RMS de apenas cinco canais de aquisição do Voluntário 3.




4.3.3 Variação do tamanho do conjunto de treinamento

Os números apresentados a seguir são produto do arranjo de teste que explora a variação das dimensões das bases de teste e treinamento descritas pelo valor RMS dos sete canais adquiridos durante os ensaios, semelhante à Seção 4.3.1.1.

Sabendo que a constituição das bases de teste e treinamento é feita aleatoriamente a partir da restrição sobre a porcentagem dos dados da base completa que deve ser atribuída a

cada uma delas e, que existem movimentos mais facilmente identificados do que outros, há casos em que, mesmo aumentando a base de treinamento, uma diminuição na taxa de acerto geral é observada. Entretanto, de modo geral, como já explicado na Seção 3.4.3, ao ampliar a base de treinamento o classificador torna-se cada vez mais apto a capturar as particularidades necessárias ao seu bom desempenho. Este aspecto é constatado no gráfico exibido na Figura 49 onde, via de regra, a taxa de acerto geral aumenta com as dimensões da base de treinamento.

Figura 49: Parcela da base total utilizada para o conjunto de treinamento X Taxa de acerto geral.



A fim de explorar o efeito sobre a escolha da composição dos conjuntos de teste e treinamento foi usado um conjunto de dados de treinamento com apenas 22.9% da base total e, um conjunto de verificação formado pelos 165 observações restantes. A Tabela 28 mostra a distribuição dos movimentos nesta base de teste.

Tabela 28: Distribuição dos movimentos da base de teste.

Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Total
Repetições	19	18	18	19	19	19	16	19	18	165

Mesmo que o classificador tenha sido alimentado com apenas 49 movimentos, a eficácia do algoritmo foi constatada em 69.1% dos casos testados, ou seja, a previsão foi correta em 114 observações das 165 averiguadas.

Tabela 29: Taxa de acerto dos movimentos e taxa de acerto geral.


Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Geral
Taxa de acerto %	36.8	83.3	38.9	78.9	78.9	73.7	75	84.2	72.2	69.1

Mais uma vez a Tabela 30 revela a desorientação do algoritmo frente a decisão de categorizar os movimentos compostos e seus originários movimentos simples. Este fato se faz presente, principalmente, na detecção dos Falsos Positivos em RAF e CMF, que são confundidos, respectivamente, com RA e CM em quase 70% dos casos.

Tabela 30: Matriz de decisão do classificador frente a cada categoria de movimento.

	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Geral
RA	7	2	0	4	0	3	0	1	2	19
FA	1	15	0	0	0	2	0	0	0	18
CM	0	1	10	0	0	0	6	0	1	18
FP	0	0	0	15	0	0	3	1	0	19
EP	0	0	0	0	17	0	0	2	0	19
RAF	0	2	0	0	0	14	0	0	3	19
CMF	0	1	4	0	0	0	10	0	1	16
EFP	0	0	1	1	2	0	0	15	0	19
RAC	0	1	2	1	0	0	2	1	11	18

Figura 50: Resultados do Voluntário 3 com classificador modelado utilizando o conjunto de treinamento formado por apenas 22.9% da base completa de observações.



4.4 Voluntário 4

O Voluntário 4 realizou um ensaio produzindo uma base de dados com um total de 124 movimentos rotulados e, especificados pela Tabela 31. A Figura 51 expõe a calibração do canal utilizado durante os ensaios para capturar os sinais produzidos pelo bíceps braquial. A calibração dos demais canais é apresentada no APÊNDICE – calibração do Voluntário 4.

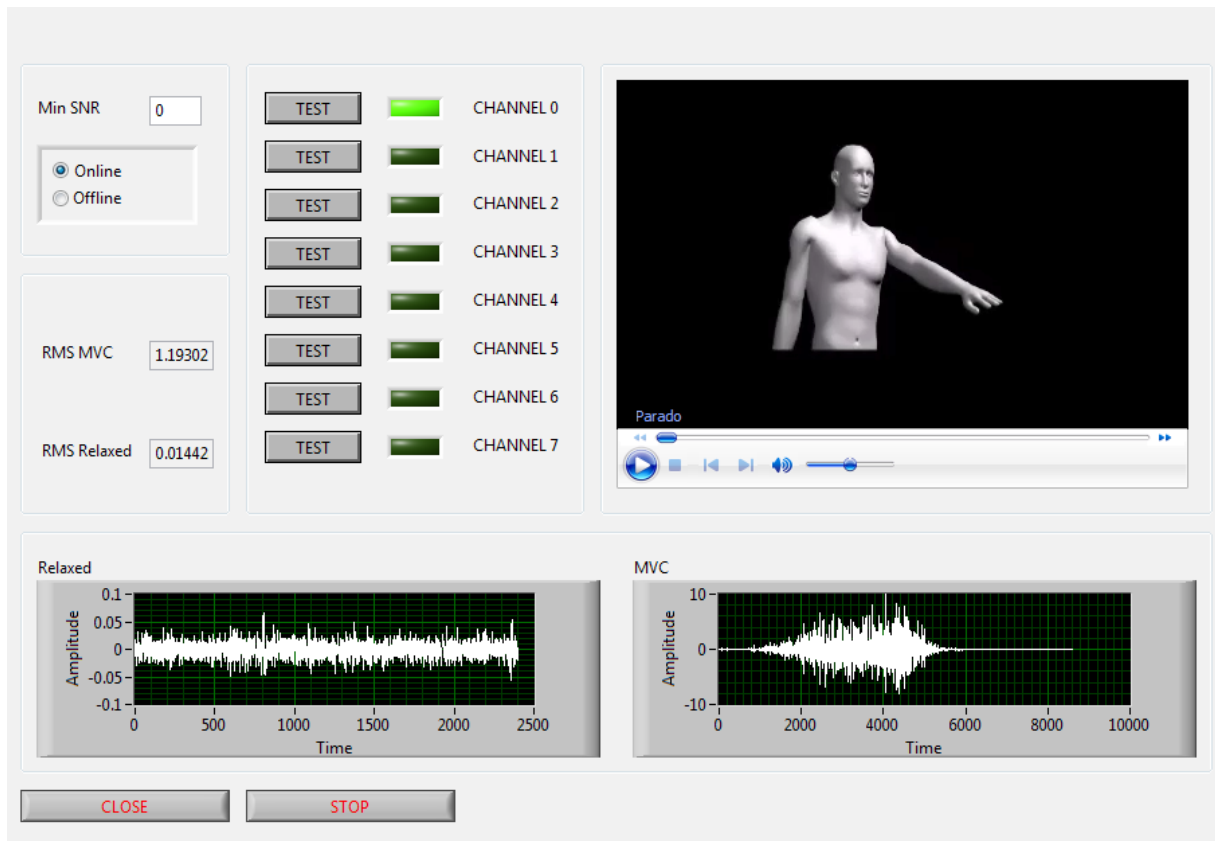
Tabela 31: Movimentos realizados pelo Voluntário 4 durante o ensaio.

Movimento	[rótulo]	Repetições
Rotação do Antebraço	[1]	14
Flexão do Antebraço	[2]	14
Contração da Mão	[3]	13
Flexão do Punho	[4]	14
Extensão do Punho	[5]	14
Rotação e Flexão do Antebraço	[6]	13
Contração da Mão e Flexão do antebraço	[7]	14

Continuação da Tabela 31.

Extensão e Flexão do Punho [8]	14
Rotação do Antebraço e Contração da mão[9]	14
Total de movimentos	124

Figura 51: Calibração do canal zero referente ao bíceps braquial do Voluntário 4.



4.4.1 Variação de características utilizadas

Os resultados apresentados a seguir foram alcançados utilizando informações de todos os sete canais através dos quais os dados foram adquiridos. Foi usado um conjunto de dados de teste formado por 15.3% dos gestos reproduzidos pelo Voluntário 4 e, um conjunto de treinamento formado pelos dados restantes. A Tabela 32 mostra a distribuição dos movimentos nesta base de teste.

Tabela 32: Distribuição dos movimentos que formam a base de dados de teste usado na Seção 4.4.1.

Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Total
Repetições	1	2	1	3	3	1	3	3	2	19

4.4.1.1 RMS

A caracterização dos movimentos através apenas do valor RMS, dos sinais advindos dos sete canais de aquisição, foi capaz de produzir para este caso e base de dados de teste uma taxa de acerto geral de 89.5% para o parâmetro regulador $\lambda=10^5$, como mostra a Figura 52. A Tabela 33 revela quais movimentos o algoritmo tem maior dificuldade de prever corretamente. É apurado que os movimentos EP e RAC possuem os piores desempenhos, sendo devidamente classificados em apenas 66.6% e 50% dos casos, respectivamente.

Tabela 33: Taxa de acerto dos movimentos e taxa de acerto geral.


Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Geral
Taxa de acerto %	100	100	100	100	66.6	100	100	100	50	89.5

Analisando a Tabela 34 é possível averiguar que o movimento RAC aparece apenas duas vezes na lista de observações testada e, por isso, ao ser mal identificado como uma CM uma vez, tem sua taxa de acerto individual bastante afetada, caindo para 50%. O mesmo pode-se dizer do movimento de EP que é classificado uma vez como RA e acaba tendo uma eficiência de 66.6%.

Tabela 34: Matriz de decisão do classificador frente a cada categoria de movimento.

	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Total
RA	1	0	0	0	0	0	0	0	0	1
FA	0	2	0	0	0	0	0	0	0	2
CM	0	0	1	0	0	0	0	0	0	1
FP	0	0	0	3	0	0	0	0	0	3
EP	1	0	0	0	2	0	0	0	0	3
RAF	0	0	0	0	0	1	0	0	0	1
CMF	0	0	0	0	0	0	3	0	0	3
EFP	0	0	0	0	0	0	0	3	0	3
RAC	0	0	1	0	0	0	0	0	1	2


Figura 52: Resultados do Voluntário 4 usando apenas RMS para caracterizar os sete canais de aquisição.



4.4.1.2 Obliquidade


Ao implementar a descrição dos movimentos através apenas de uma das características apresentadas na Seção 3.3.5 foram obtidos os resultados expostos na Figura 53. Portanto, o valor que melhor descreve um sinal mioelétrico do conjunto de dados do Voluntário 4 é obliquidade.

Figura 53: Desempenho do classificador para descrição dos dados do Voluntário 4 através de cada característica individualmente.



Ao caracterizar os movimentos utilizando o valor de obliquidade, no lugar de utilizar RMS, a taxa de acerto geral obteve uma melhoria de 11.8% chegando ao índice máximo de 100% de sucesso, como mostra a Figura 54.

Figura 54: Resultados do Voluntário 4 usando obliquidade para caracterizar os sete canais de aquisição.



4.4.2 Variação do número de canais utilizados

Utilizando novamente a configuração da Seção 4.4.1.1, que descreve os movimentos através apenas do valor RMS, é apresentada por meio da Figura 55 o desempenho do algoritmo com a variação do número de canais utilizados. A diminuição do número de canais implica na diminuição da quantidade de dados que definem a decisão do algoritmo e do número de eletrodos necessários, facilitando a implementação real das próteses.

O gráfico exibido pela Figura 55 revela que ao considerar os canais zero, um e três a taxa de acerto geral apresenta melhorias significativas. Por esta razão é apresentado a seguir os resultados detalhados do uso desses três canais. A Tabela 35 evidencia o sucesso do algoritmo em 94.7% dos casos de teste, como mostra a Figura 56, ou seja, um aumento de 5.9% do desempenho em relação ao uso dos sete canais originais.

Figura 55: Desempenho do classificador X Canais para o Voluntário 4.





Tabela 35: Taxa de acerto dos movimentos e taxa de acerto geral.

Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Geral
Taxa de acerto %	100	100	100	100	66.6	100	100	100	100	94.7

Figura 56: Resultados do Voluntário 4 usando RMS para caracterizar três canais.




4.4.3 Variação do tamanho do conjunto de treinamento

Os números apresentados a seguir são produto do arranjo de teste formado por dimensões variáveis das bases de testes e treinamento descritas pelo valor RMS dos sete canais adquiridos durante os ensaios, semelhante à Seção 4.4.1.1.

Sabendo que a constituição das bases de teste e treinamento é feita aleatoriamente a partir da restrição sobre a porcentagem de dados que deve ser atribuída a cada uma delas e, que existem movimentos mais facilmente identificados do que outros, há casos em que, mesmo aumentando a base de treinamento, uma diminuição na taxa de acerto geral é observada. Entretanto, de modo geral, como já explicado na Seção 3.4.3, ao ampliar a base de treinamento o classificador torna-se cada vez mais apto a capturar as particularidades necessárias ao seu bom desempenho. Este aspecto é constatado no gráfico exibido na Figura 57 onde, via de regra, a taxa de acerto geral aumento com as dimensões da base de treinamento.

Figura 57: Parcela da base total utilizada para o conjunto de treinamento X Taxa de acerto geral.



Dentre as possibilidades testadas, a utilização de uma base de treinamento com 11.3% revelou uma taxa de sucesso relativamente alta em relação as demais, dada suas restrições. Este arranjo de teste utilizou apenas 14 movimentos, dos 124 produzidos pelo Voluntário 4 durante o ensaio, para criar o modelo do classificador e, mesmo assim, obteve sucesso em 80% dos 110 movimentos testados, ou seja, categorizou corretamente 88 gestos.

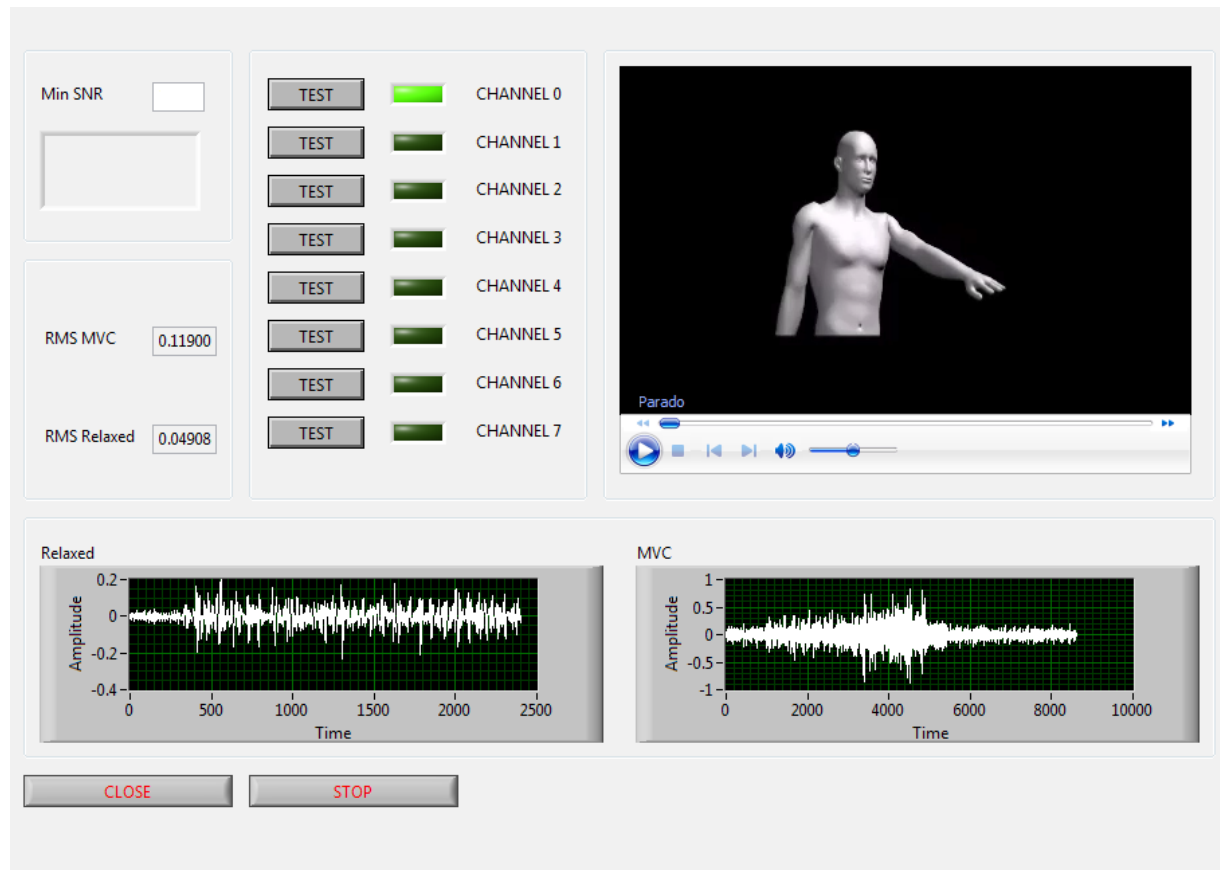
4.5 Voluntário 5

O Voluntário 5 realizou um ensaio produzindo um banco de dados com um total de 180 movimentos rotulados e, especificados pela Tabela 36. A Figura 58 expõe a calibração do canal utilizado durante os ensaios para capturar os sinais produzidos pelo bíceps braquial. A calibração dos demais canais é apresentada no APÊNDICE – calibração do Voluntário 5.

Tabela 36: Movimentos realizados pelo Voluntário 5 durante o ensaio.

Movimento	[rótulo]	Repetições
Rotação do Antebraço	[1]	20
Flexão do Antebraço	[2]	20
Contração da Mão	[3]	20
Flexão do Punho	[4]	20
Extensão do Punho	[5]	20
Rotação e Flexão do Antebraço	[6]	20
Contração da Mão e Flexão do antebraço	[7]	20
Extensão e Flexão do Punho	[8]	20
Rotação do Antebraço e Contração da mão	[9]	20
Total de movimentos		180

Figura 58: Calibração do canal zero referente ao bíceps braquial do Voluntário 5.



4.5.1 Variação das características utilizadas

Os resultados apresentados a seguir foram alcançados utilizando informações de todos os sete canais através dos quais os dados foram adquiridos. O complexo de dados de teste é composto por 16.6% dos gestos que formam a base total e, o conjunto de treinamento é elaborado pelos dados restantes. A Tabela 37 mostra a distribuição dos movimentos neste reservatório de teste.

Tabela 37: Distribuição dos movimentos que formam a base de dados de teste usado na Seção 4.5.1.

Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Total
Repetições	4	4	2	4	4	1	4	4	3	30

4.5.1.1 RMS

A caracterização dos movimentos através apenas do valor RMS, dos sinais advindos dos sete canais de aquisição, foi capaz de produzir, para este caso e base de dados de teste, uma taxa de acerto geral de 86.6% para o parâmetro regulador $\lambda=10^5$, como mostra a Figura 59. A Tabela 38 revela quais movimentos o algoritmo tem maior dificuldade de prever corretamente. É apurado que os movimentos RA, FA, CM e CMF possuem os piores desempenhos, sendo devidamente classificados em 75%, 75%, 50% e 75% dos casos, respectivamente.

Figura 59: Resultados do Voluntário 5 usando apenas RMS para caracterizar os sete canais de aquisição.

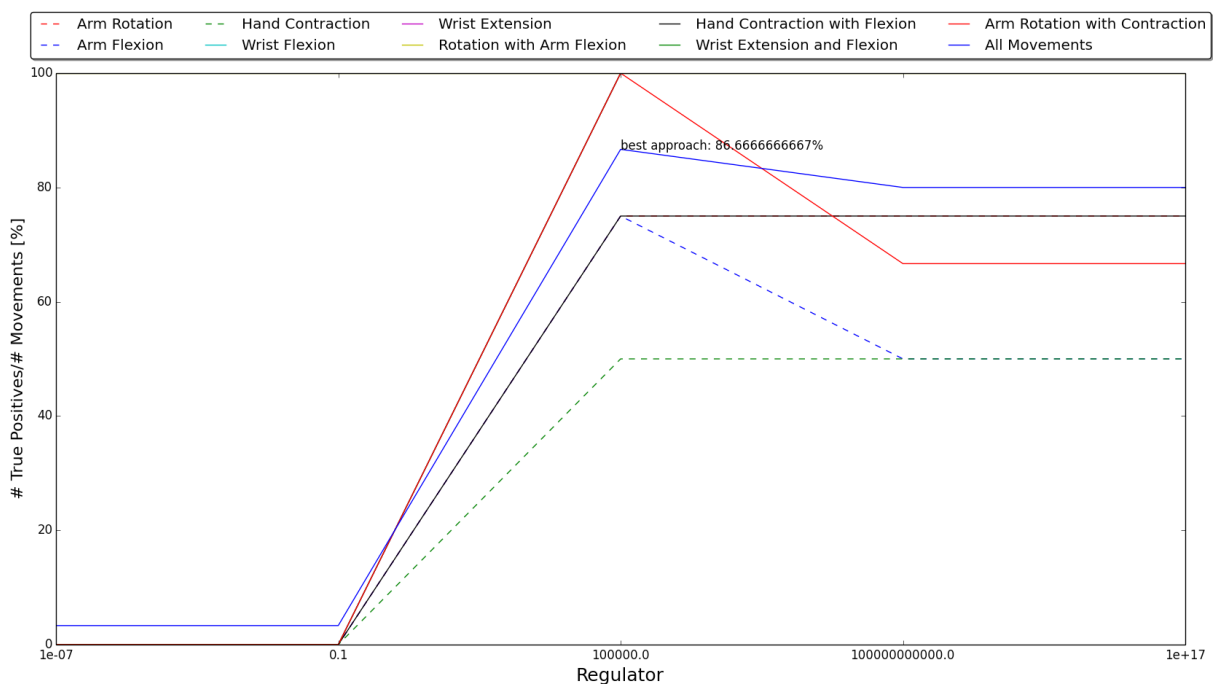


Tabela 38: Taxa de acerto dos movimentos e taxa de acerto geral.

Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Geral
Taxa de acerto %	75	75	50	100	100	100	75	100	100	86.6

Analisando a Tabela 39 é possível averiguar que as dificuldades enfrentadas pelo classificador estão, em grande parte, ligadas aos movimentos que contém o gesto elementar de contração da mão.

Tabela 39: Matriz de decisão do classificador frente a cada categoria de movimento.

	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Total
RA	3	0	0	0	0	0	1	0	0	4


Continuação da Tabela 39.

FA	0	3	0	0	0	0	0	0	1	4
CM	0	0	1	0	0	0	1	0	0	2
FP	0	0	0	4	0	0	0	0	0	4
EP	0	0	0	0	4	0	0	0	0	4
RAF	0	0	0	0	0	1	0	0	0	1
CMF	0	0	0	0	0	0	3	0	1	4
EFP	0	0	0	0	0	0	0	4	0	4
RAC	0	0	0	0	0	0	0	0	3	3

4.5.1.2 RMS, desvio padrão, variância e obliquidade


Ao implementar a descrição dos movimentos através de cada uma das características apresentadas na Seção 3.3.5, individualmente, foram obtidos os resultados expostos na Figura 60. Portanto, a extração isolada dos valores RMS e desvio padrão é a melhor forma de descrição das observações geradas pelo Voluntário 5.

Figura 60: Desempenho do classificador para descrição dos dados do Voluntário 5 através de cada característica individualmente.



Ao caracterizar os movimentos utilizando os valores de RMS, desvio padrão, variância e obliquidade em conjunto, no lugar de utilizar apenas RMS, a taxa de acerto geral obteve uma melhoria de 11.5% chegando ao índice de 96.6% de sucesso, como mostra a Figura 61 e a Tabela 40. Este aperfeiçoamento é alcançado devido a melhor descrição do sinal e,

Figura 61: Resultados do Voluntário 5 usando RMS, desvio padrão, variância e obliquidade em conjunto para caracterizar os sete canais de aquisição.



4.5.2 Variação do número de canais utilizados


Utilizando novamente a configuração da Seção 4.5.1.1, que descreve os movimentos através apenas do valor RMS, é apresentada por meio da Figura 62 o desempenho do algoritmo com a variação do número de canais utilizados. A diminuição do número de canais implica na diminuição da quantidade de dados que definem a decisão do algoritmo e do número de eletrodos necessários, facilitando a implementação real das próteses.

O gráfico exibido pela Figura 62 revela que ao considerar o canal três há uma piora do desempenho assim como, ao considerar o canal quatro há uma compensação porém, não significativa. Por esta razão é apresentado a seguir os resultados detalhados do uso de apenas cinco canais, tendo sido desconsiderados os canais três e quatro, para descrever os gestos. A Tabela 42 evidencia o sucesso do algoritmo em 90% dos casos de teste, ou seja, um aumento de 3.8% do desempenho em relação ao uso dos sete canais originais (Figura 63).

Tabela 42: Taxa de acerto dos movimentos e taxa de acerto geral.

Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Geral
Taxa de acerto %	75	75	100	100	100	100	75	100	100	90

Figura 63: Desempenho do classificar para a caracterização do sinal através do valor RMS de apenas cinco canais de aquisição do Voluntário 5.




4.5.3 Variação do tamanho do conjunto de treinamento

Os números apresentados a seguir são produto do arranjo de teste formado por dimensões variáveis das bases de testes e treinamento descritas pelo valor RMS dos sete canais adquiridos durante os ensaios, semelhante à Seção 4.5.1.1.

Sabendo que a constituição das bases de teste e treinamento é feita aleatoriamente a partir da restrição sobre a porcentagem de dados que deve ser atribuída a cada uma delas e, que existem movimentos mais facilmente identificados do que outros, há casos em que, mesmo aumentando a base de treinamento, uma diminuição na taxa de acerto geral é observada. Entretanto, de modo geral, como já explicado na Seção 3.4.3, ao ampliar a base de treinamento o classificador torna-se cada vez mais apto a capturar as particularidades necessárias ao seu bom desempenho. Este aspecto é constatado no gráfico exibido na Figura 64 onde, via de regra, a taxa de acerto geral aumento com as dimensões da base de treinamento.

Figura 64: Parcela da base total utilizada para o conjunto de treinamento X Taxa de acerto geral.



Dentre as possibilidades testadas, a utilização de uma base de treinamento com 32.2% revelou uma taxa de sucesso relativamente alta em relação as demais, dada suas restrições. Este arranjo de teste utilizou apenas 58 movimentos, dos 180 produzidos pelo Voluntário 5 durante os ensaios, para criar o modelo do classificador e, mesmo assim, obteve sucesso em 85.2% dos 122 movimentos testados, ou seja, categorizou corretamente 104 gestos.

4.6 Todos voluntários

Para a realização deste trabalho foram adquiridos sinais de 1058 movimentos reproduzidos por cinco voluntários diferentes. A Tabela 44 mostra a distribuição desta base de dados completa segundo os nove movimentos englobados pelo contexto desta pesquisa.

Tabela 44: Movimentos realizados pelos cinco voluntários.

Movimento	[rótulo]	Repetições
Rotação do Antebraço	[1]	118
Flexão do Antebraço	[2]	117
Contração da Mão	[3]	117
Flexão do Punho	[4]	118

Continuação da Tabela 44.

Extensão do Punho	[5]	117
Rotação e Flexão do Antebraço	[6]	117
Contração da Mão e Flexão do antebraço	[7]	118
Extensão e Flexão do Punho	[8]	118
Rotação do Antebraço e Contração da mão[9]		118
Total de movimentos		1058

A fim de analisar a capacidade de generalização do modelo, foi criada uma base de dados de treinamento formada pelas informações resultantes dos ensaios de quatro voluntários e, uma base de teste com os dados do voluntário restante. A caracterização dos movimentos reproduzidos pelos voluntários um, três, quatro e cinco formaram o conjunto de treinamento e, portanto, foram os responsáveis pela formação do modelo deste caso de teste e; os movimentos caracterizados pelo Voluntário 2, que não são considerados na modelização do classificador, foram testados através deste modelo.

4.6.1 Variação das características utilizadas

Os resultados apresentados a seguir foram alcançados utilizando informações de todos os sete canais através dos quais os dados foram adquiridos. O complexo de dados de teste é composto por 10.2% dos gestos que formam a base total e, o conjunto de treinamento é elaborado pelos dados restantes. A Tabela 45 mostra a distribuição dos movimentos neste reservatório de teste.

Tabela 45: Distribuição dos movimentos que formam a base de dados de teste usado na Seção 4.6.1.

Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Total
Repetições	12	12	12	12	12	12	12	12	12	108

4.6.1.1 RMS

A caracterização dos movimentos através apenas do valor RMS, dos sinais advindos dos sete canais de aquisição, foi capaz de produzir, para este caso e base de dados de teste,

uma taxa de acerto geral de 63%, classificando corretamente 68 movimentos, para o parâmetro regulador $\lambda=10^5$, como mostra a Figura 65.

A Tabela 46 revela quais movimentos o algoritmo tem maior dificuldade de prever corretamente. É apurado que os movimentos RA, CMF e RAC possuem os piores desempenhos, sendo devidamente classificados em 33.3%, 33.3% e 0% dos casos, respectivamente.

Figura 65: Resultados do Voluntário 5 usando apenas RMS para caracterizar os sete canais de aquisição.




Tabela 46: Taxa de acerto dos movimentos e taxa de acerto geral.

Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Geral
Taxa de acerto %	33.3	75	83.3	91.6	100	83.3	33.3	66.6	0	63

Analisando a Tabela 47 é possível averiguar as dificuldades enfrentadas pelo classificador. Mais uma vez os movimentos de RA e FA, que possuem o músculo principal de ativação comum – bíceps braquial –, são confundidos, assim como ocorreu no caso de teste apresentado na Seção 4.3.1.2. Os movimentos compostos e os respectivos originários também foram confundidos durante a classificação, como é o caso da consideração, em repetidos casos, do movimento de CMF como CM.

Tabela 47: Matriz de decisão do classificador frente a cada categoria de movimento.


	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Total
RA	4	8	0	0	0	0	0	0	0	12
FA	2	9	0	0	0	0	1	0	0	12
CM	0	0	10	2	0	0	0	0	0	12
FP	0	0	0	11	0	0	0	1	0	12
EP	0	0	0	0	12	0	0	0	0	12
RAF	1	1	0	0	0	10	0	0	0	12
CMF	0	0	6	2	0	0	4	0	0	12
EFP	0	0	4	0	0	0	0	8	0	12
RAC	2	5	0	0	0	3	2	0	0	12

4.6.1.2 RMS, desvio padrão e variância

Mais uma vez é utilizado, para este caso, todos os setes canais da configuração de base de teste e treinamento apresentada na Seção 4.6.1.1. Contudo, a caracterização do sinal é feita através, não somente do valor RMS, mas também do desvio padrão e variância. Segundo a Figura 66 estas características, quando testadas individualmente, apresentam resultados idênticos, classificando corretamente 63% dos gestos testados.

Pelo fato das características não serem capazes de salientar peculiaridades diferentes em relação a cada movimento, para este indivíduo, o resultado final apresentado pelo classificador que utiliza estas características em conjunto para descrever um gesto, mantém o resultado geral de 63%. Este desempenho é detalhado na Seção 4.6.1.1 pela Tabela 46 e pela Tabela 47.

Figura 66: Desempenho do classificador para descrição dos dados de todos os voluntários através de cada característica individualmente.



4.6.2 Variação do número de canais utilizados


Utilizando novamente a configuração da Seção 4.6.1.1, que descreve os movimentos através apenas do valor RMS, é apresentada por meio da Figura 67 o desempenho do algoritmo com a variação do número de canais utilizados. A diminuição do número de canais implica na diminuição da quantidade de dados que definem a decisão do algoritmo e do número de eletrodos necessários, facilitando a implementação real das próteses.

O gráfico exibido pela Figura 67 revela que ao considerar o canal dois há uma piora do desempenho. Por esta razão é apresentado a seguir os resultados detalhados da desconsideração deste canal. A Tabela 48 evidencia o sucesso do algoritmo em 62% dos casos de teste, ou seja, uma piora de apenas 1.5% em relação ao uso dos sete canais originais (Figura 68), ou seja, utilizando apenas 85.7% do volume de informação original obtêm-se um resultado equivalente.

Tabela 48: Taxa de acerto dos movimentos e taxa de acerto geral.

Movimentos	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Geral
Taxa de acerto %	50	50	83.3	91.6	100	91.6	16.6	75	0	62

Figura 67: Desempenho do classificador X Canais para todos os voluntários.




A Tabela 49 expõe a dificuldade do modelo gerado a partir desta configuração de identificar movimentos que possuem gestos em comum ou, músculos ativadores em comum como é o caso dos movimentos de CMF e RAC, que apresentam os piores desempenhos: 16.6% e 0%, respectivamente.

Tabela 49: Matriz de decisão do classificador frente a cada categoria de movimento.

	RA	FA	CM	FP	EP	RAF	CMF	EFP	RAC	Total
RA	6	6	0	0	0	0	0	0	0	12
FA	6	6	0	0	0	0	0	0	0	12
CM	0	0	10	2	0	0	0	0	0	12
FP	0	0	0	11	0	0	0	1	0	12
EP	0	0	0	0	12	0	0	0	0	12
RAF	1	0	0	0	0	11	0	0	0	12
CMF	0	0	8	2	0	0	2	0	0	12
EFP	0	0	3	0	0	0	0	9	0	12
RAC	3	5	0	0	0	4	0	0	0	12

Figura 68: Desempenho do classificador para a caracterização do sinal através do valor RMS de apenas seis canais de aquisição.



5 CONCLUSÃO

A exploração do funcionamento do método matemático de regressão logística, aplicado a caracterização dos sinais mioelétricos produzidos durante os movimentos do segmento mão-braço, revelou bons resultados e potenciais de melhoria. A média dos melhores desempenhos do modelo aplicado aos cinco voluntários atingiu uma taxa de acerto de 95%, com um desvio padrão de 4.2%, sendo que o melhor caso classificou corretamente 100% dos movimentos.

Analisando as configurações de teste em que o classificador desempenhou os melhores resultados em cada voluntário, 77.8% dos erros de categorização do movimento foram cometidos entre movimentos que possuem gestos em comum, ou seja, entre o gesto composto e o seu originário. Apenas 11.1% dos erros são advindos da confusão entre movimentos que possuem o mesmo músculo principal de ativação, como é o caso da Flexão do Antebraço e a Rotação do Antebraço.

Estas análises tornam possível a exaltação da importância da escolha de músculos que sejam capazes de diferenciar os movimentos e, portanto, ao terem seus sinais combinados sejam capazes de individualizar as características de cada movimento, evitando categorizações equivocadas por parte do classificador. Além disto, é importante acompanhar atentamente a realização dos movimentos reproduzidos pelos voluntários a fim de produzir um conjunto de dados coerente. Após algumas repetições o ensaio pode tornar-se maçante e, portanto, é necessário reforçar a necessidade da atenção sobre os movimentos demonstrados nos vídeos reproduzidos durante a rotina de aquisição do sinal.

REFERÊNCIAS

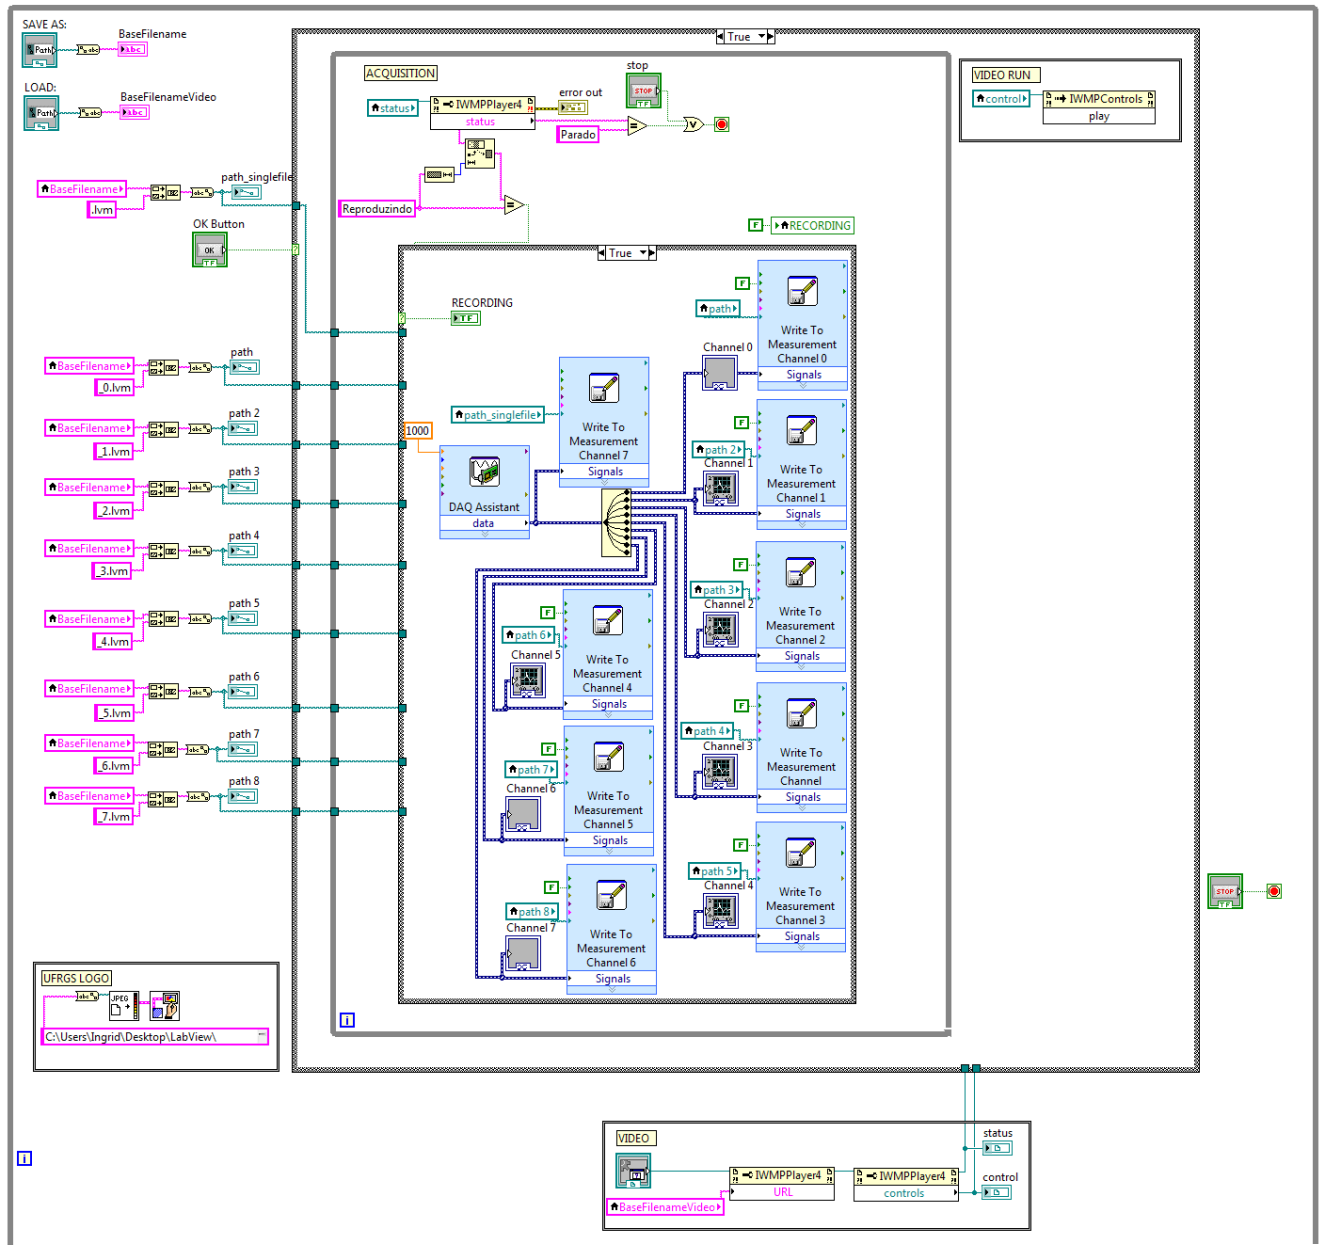
- BERMUDEZ, R.. **Proposta de um sistema Baseado em Redes Neurais e Wavelets para Caracterização de Movimentos do Segmento Mão-Braço**. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2013.
- BISHOP, CHRISTOPHER M.. **Pattern Recognition and Machine Learning**. Springer, 2006.
- BORON, WALTER F.; BOULPAEP, EMILE L.. **Medical Physiology**. W.B. Saunders, 2003.
- BUNDERSON, NATHAN E.. **Real-Time Control of an Interactive Impulsive Virtual Prosthesis**. IEEE Transactions on Neural Systems and Rehabilitation Engineering, pp. 363-370, 2014.
- CHIH-WEI, HSU; CHIH-CHUNG, CHANG; CHIH-JEN, LIN. **A Practical Guide to Support Vector Classification**. National Taiwan University, Taipei, 2003.
- CHRISTODOULOU; PATTICHIS. **A new technique for the classification and decomposition of EMG signals**. Proc. IEEE Int. Conf. on Neural Networks, Perth, Western Australia, pp. 2303 - 2308, 1995.
- CONTO, E.; BALBINOT, A. **Ambientes virtuais controláveis por sinais mioelétricos**. SALÃO DE INICIAÇÃO CIENTÍFICA DO IC/FUC. Porto Alegre, 2011.
- DE LUCA, CARLOS J.. **Physiology and Mathematics of Myoelectric Signals**. IEEE Transactions on Biomedical Engineering, pp. 313 - 325, 2007.
- DE LUCA, CARLOS J.. **Surface Electromyography: Detection and Recording**. Delsys Incorporated, 2002.
- DE LUCA; GILMORE; KUZNETSOV, ROY. **Filtering the surface EMG signal: Movement artifact and baseline noise contamination**. Journal of Biomechanics, pp. 1573 - 1579, 2010.
- FAVIERO, G. W.. **Desenvolvimento de um sistema neuro-fuzzy para análise de sinais mioelétricos do segmento mão-braço**. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Rio Grande do Sul. Porto Alegre, 2012.

- HAHNE, J. M.; BIESSMANN, F.; JIANG, N.; REHBAUM, H.; FARINA, D.; MEINECKE, F. C.; MÜLLER, K.-R.; PARRA, L. C.. **Linear and Nonlinear Regression Techniques for Simultaneous and Proportional Myoelectric Control**. IEEE Transactions on Neural Systems and Rehabilitation Engineering, pp. 269 - 279, 2014.
- JIANG, NING; MUCELI, SILVIA; GRAIMANN, BERNHARD; FARINA, DARIO. **Effect of arm position on the prediction of kinematics from EMG in amputees**. Med. Biol. Eng. Comput., pp. 143 - 151, 2013.
- JIANG, NING; VEST-NIELSEN, JOHNNY LG; MUCELI, SILVIA; FARINA, DARIO. **EMG-based simultaneous and proportional estimation of wrist/hand kinematics in uni-lateral trans-radial amputees**. Journal of NeuroEngineering and Rehabilitation, pp. 9 – 42, 2012.
- KENT, BENJAMIN A.; KARNATI, NAREEN; ENGERBERG, ERIK D. **Electromyogram synergy control of a dexterous artificial hand to unscrew and screw objects**. Journal of NeuroEngineering and Rehabilitation, pp. 11 – 41, 2014.
- KEXIN XING; PEIPEI YANG; JIAN HUANG; YONGJI WANG; QUANMIN ZHU. **A real-time EMG pattern recognition method for virtual myoelectric hand control**. Neurocomputing, pp. 345 – 355, 2014.
- LAVALLEY, MICHAEL P.. **Logistic regression**. Department of Biostatistics, Boston University School of Public Health, 2008.
- LIN, JONATHAN; KULIĆ, DANA. **Online Segmentation of Human Motion for Automated Rehabilitation Exercise Analysis**. IEEE Transactions on Neural Systems and Rehabilitation Engineering, pp. 168 – 180, 2014.
- MCCLELLAND, JAMES L. **Integrating probabilistic models of perception and interactive neural networks: a historical and tutorial review**. Frontiers in psychology, pp. 503, 2013.
- MESA, IKER; RUBIO, ANGEL; TUBIA, IMANOL; DE NO, JOAQUIN, DIAZ, JAVIER. **Channel and feature selection for a surface electromyographic pattern recognition task**. Expert Systems with Applications, pp. 5190 – 5200, 2014.
- NILSON, CLAIRE DE P. **Aquisição, processamento de sinais mioelétricos e máquina de vetores de suporte para caracterização de movimentos do segmento mão-braço**. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2014.

- OSKOEI, MOHAMMADREZA A.; HU, HUOSHENG. **Myoelectric control systems**. Biomedical Signal Processing and Control, pp. 275 – 294, 2007.
- OUTTEN, ALAN G.; ROBERTS, STEPHEN J.; STOKES, MARIA J. **Analysis of human muscle activity**. Artificial Intelligence Methods for Biomedical Data Processing, IEE Colloquium, pp. 1 – 7, 1996.
- PERSONNIER, PASCALINE; BALLAY, YVES; PAPAXANTHIS, CHARALAMBOS. **Mentally represented motor actions in normal aging: III. Electromyographic features of imagined arm movements**. Behavioural Brain Research, pp. 184 – 191, 2010.
- TAUB, DIANE; BLINDE, ELAINE; KIMBERLY, GREER. **Stigma Management Through Participation in Sport and Physical Activity: Experiences of Male College Students with Physical Disabilities**. Human Relation, pp. 1469 – 1484, 1999.
- TORTORA, GERARD J.. **Corpo humano – Fundamentos de anatomia e fisiologia**. Artmed Editora, 2000.
- YUN, WOO-HAN; BANG, SUNG YANG; KIM, DAIJIN. **Real-time object recognition using relational dependency based on graphical model**. Department of Computer Science and Engineering, Pohang University of Science and Technology, pp. 742 – 753, 2008.

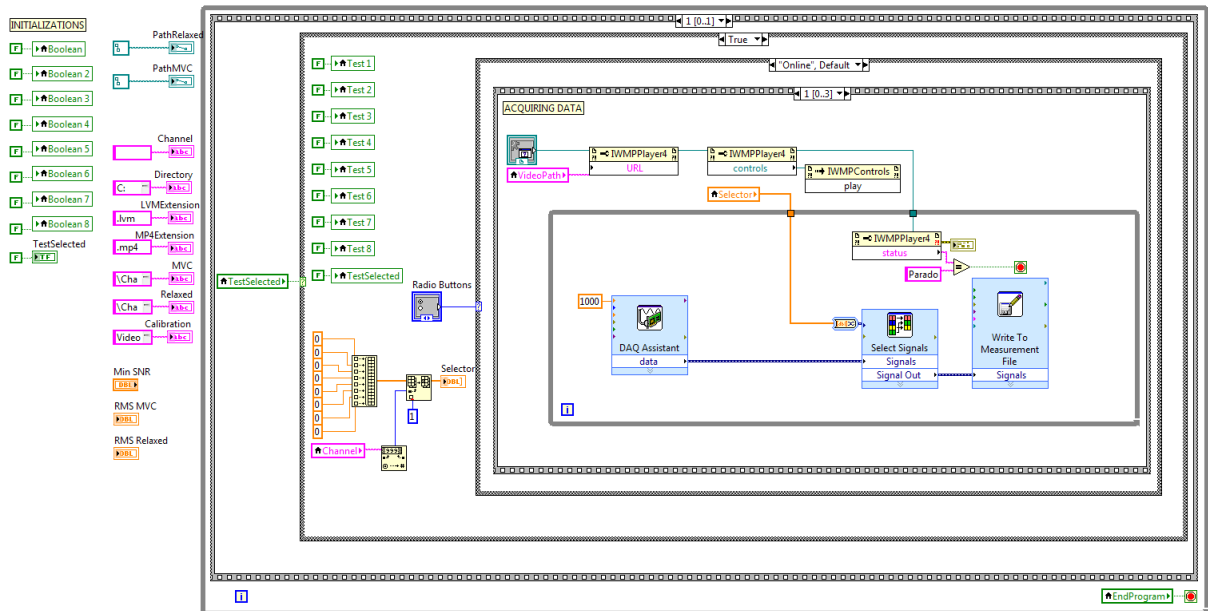
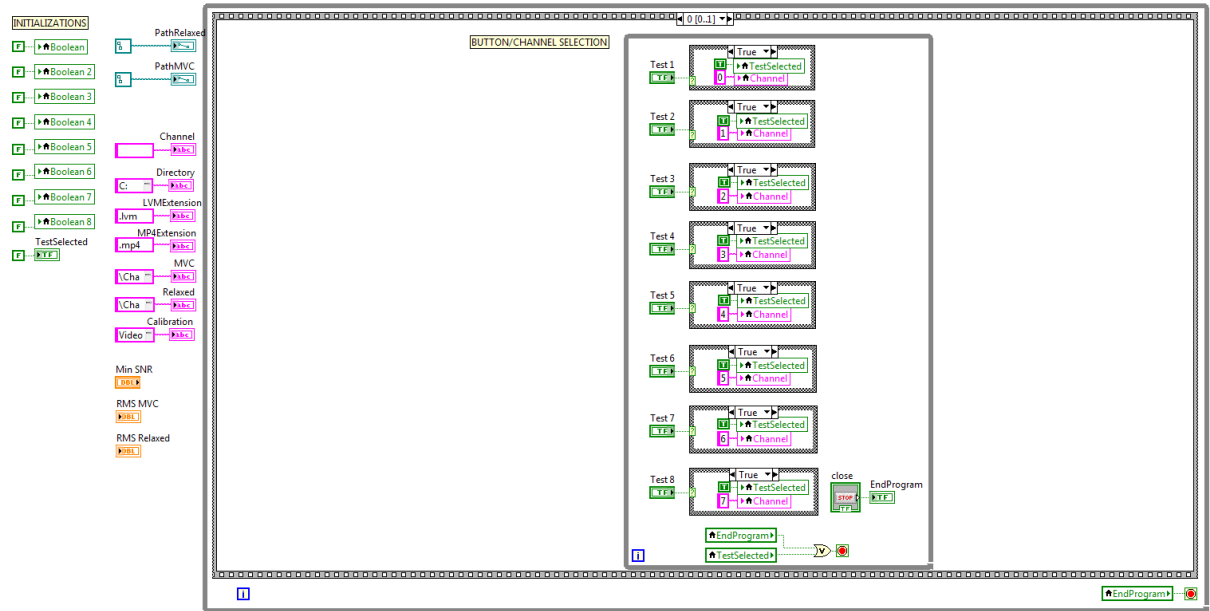
APÊNDICE – LABVIEW: AQUISIÇÃO

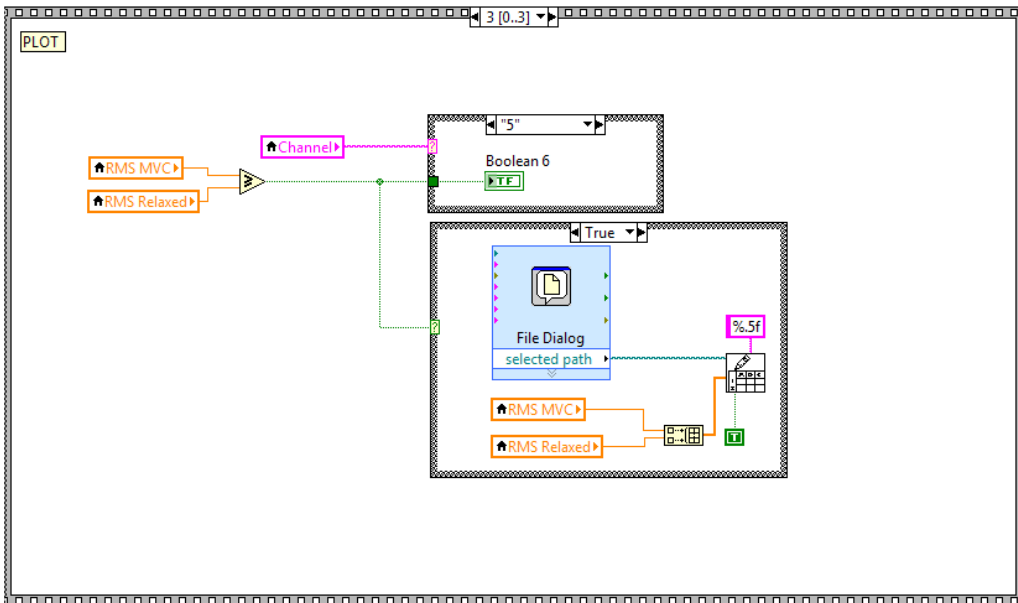
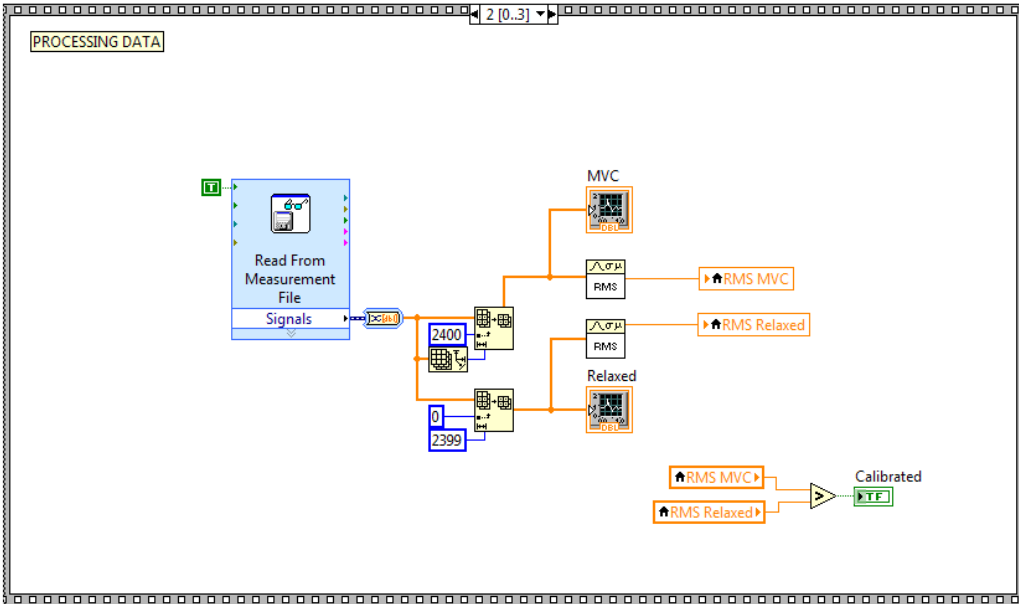
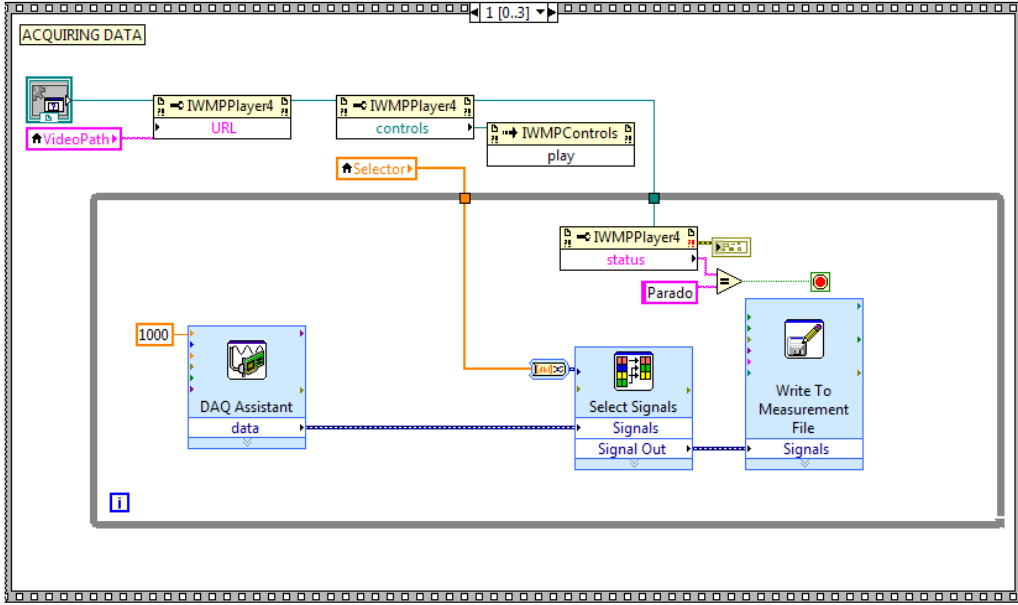
As telas apresentadas a seguir revelam o digrama de blocos construído para a rotina de aquisição de dados do sistema:



APÊNDICE – LABVIEW: CALIBRAÇÃO

As telas apresentadas a seguir revelam o digrama de blocos construído para a rotina de calibração do sistema:

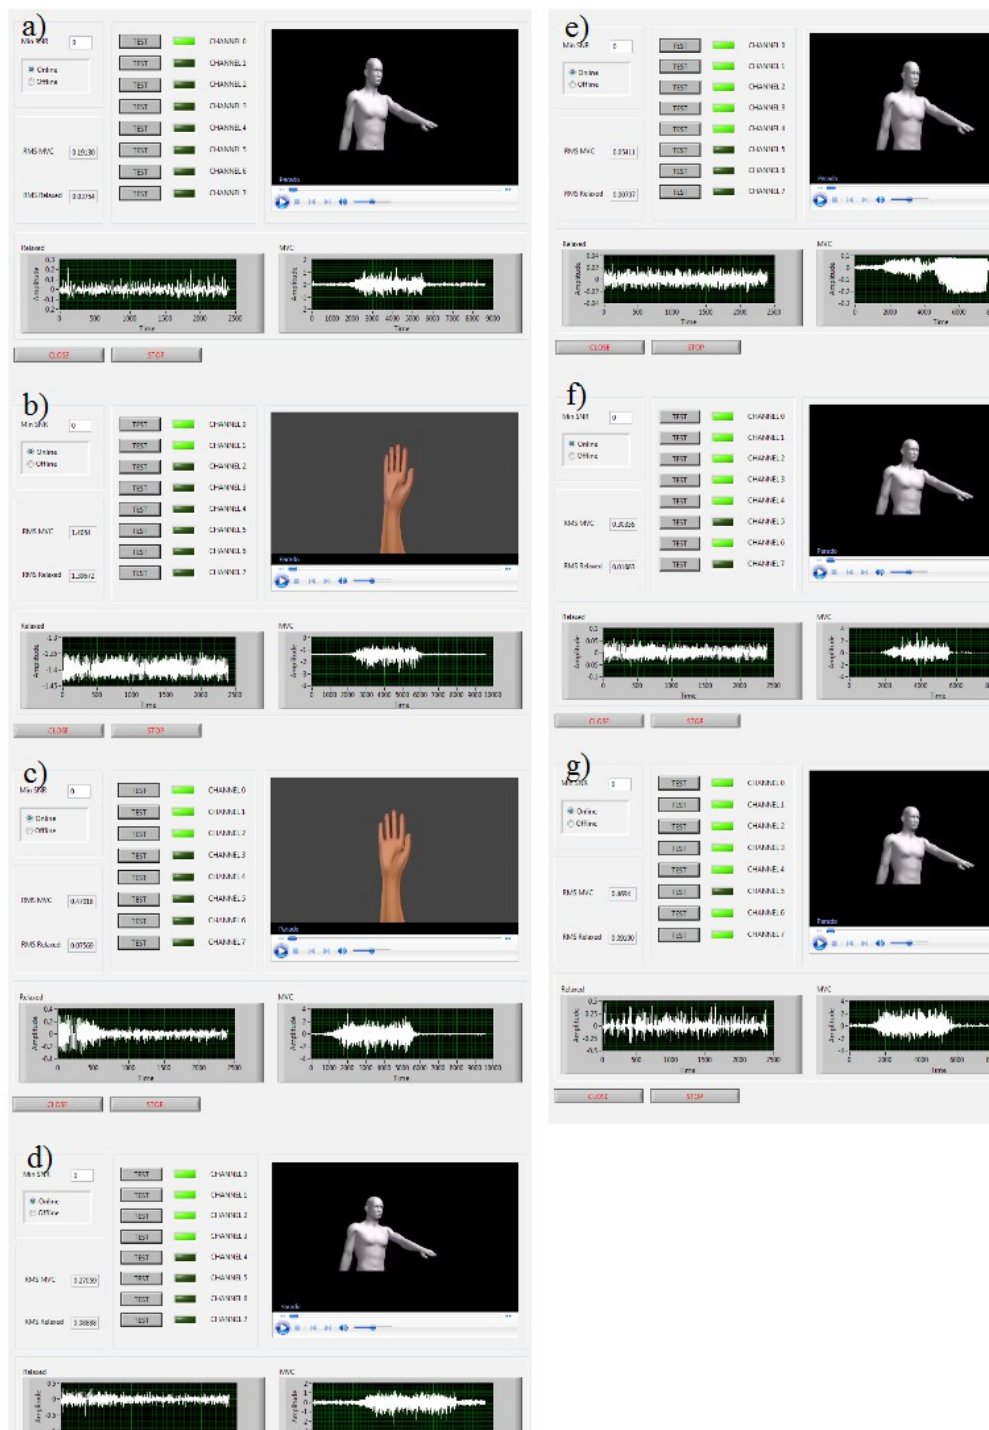




APÊNDICE – CALIBRAÇÃO DO VOLUNTÁRIO 1

A Figura 69 apresenta o painel frontal da rotina *LabVIEW* de calibração do sistema durante a realização do ensaio com o indivíduo um.

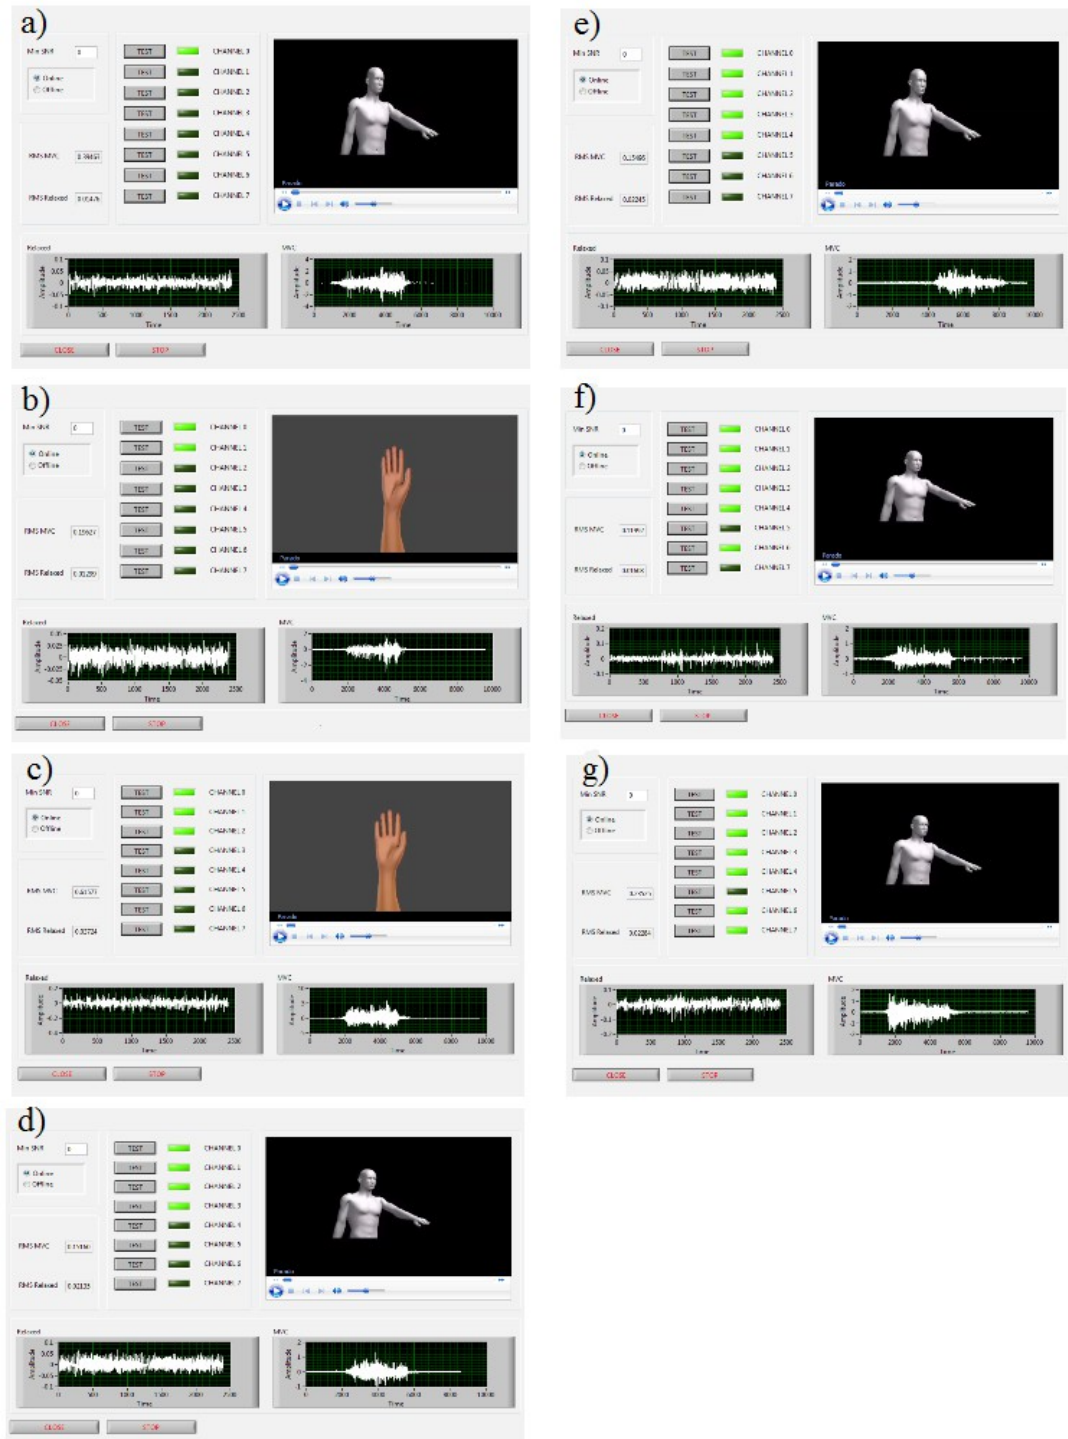
Figura 69: Calibração: a) Canal 1, b) Canal 2, c) Canal 3, d) Canal 4, e) Canal 5, f) Canal 7 e g) Canal 8.



APÊNDICE – CALIBRAÇÃO DO VOLUNTÁRIO 2

A Figura 70 apresenta o painel frontal da rotina *LabVIEW* de calibração do sistema durante a realização do ensaio com o indivíduo dois.

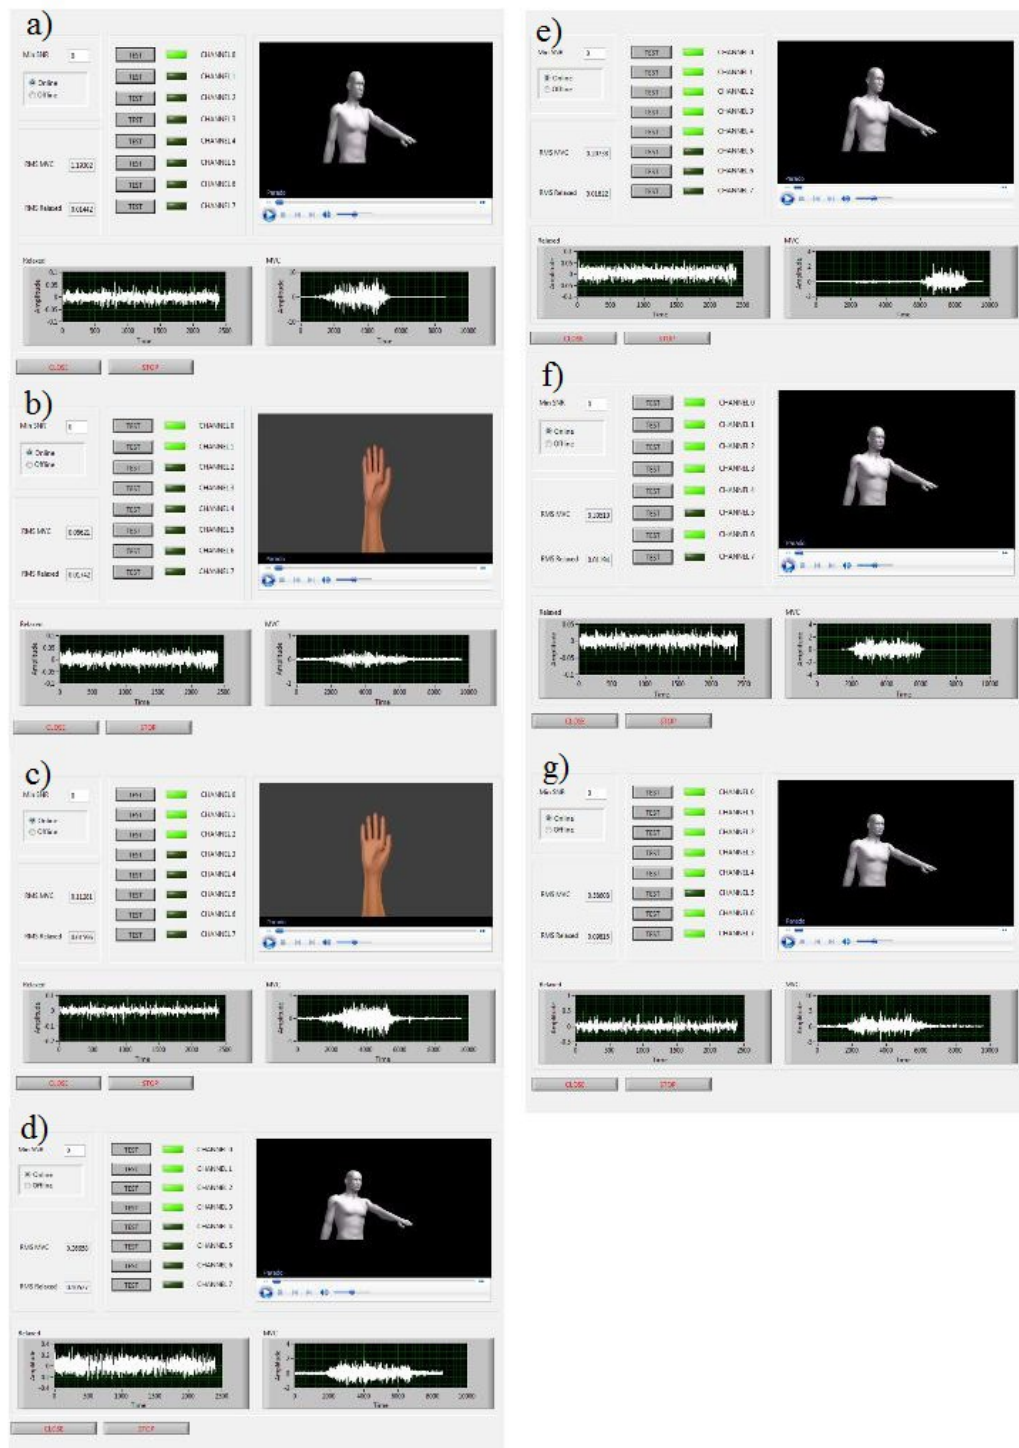
Figura 70: Calibração: a) Canal 1, b) Canal 2, c) Canal 3, d) Canal 4, e) Canal 5, f) Canal 7 e g) Canal 8.



APÊNDICE – CALIBRAÇÃO DO VOLUNTÁRIO 4

A Figura 71 apresenta o painel frontal da rotina *LabVIEW* de calibração do sistema durante a realização do ensaio com o indivíduo quatro.

Figura 71: Calibração: a) Canal 1, b) Canal 2, c) Canal 3, d) Canal 4, e) Canal 5, f) Canal 7 e g) Canal 8.



APÊNDICE – CALIBRAÇÃO DO VOLUNTÁRIO 5

A Figura 72 apresenta o painel frontal da rotina *LabVIEW* de calibração do sistema durante a realização do ensaio com o indivíduo cinco.

Figura 72: Calibração: a) Canal 1, b) Canal 2, c) Canal 3, d) Canal 4, e) Canal 5, f) Canal 7 e g) Canal 8.

