

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
ESCOLA DE ENGENHARIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

VINÍCIUS HORN CENE

**DESENVOLVIMENTO DE UM PROJETO DE  
EXPERIMENTOS PARA A CARACTERIZAÇÃO DE SINAIS  
MIOELÉTRICOS ATRAVÉS DO USO DE REGRESSÃO  
LOGÍSTICA**

Porto Alegre

2016

**VINÍCIUS HORN CENE**

**DESENVOLVIMENTO DE UM PROJETO DE  
EXPERIMENTOS PARA A CARACTERIZAÇÃO DE SINAIS  
MIOELÉTRICOS ATRAVÉS DO USO DE REGRESSÃO  
LOGÍSTICA**

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

Área de concentração: Engenharia  
de Controle e Automação - Instrumentação.

ORIENTADOR: Dr. Alexandre Balbinot

Porto Alegre

2016

VINÍCIUS HORN CENE

**DESENVOLVIMENTO DE UM PROJETO DE  
EXPERIMENTOS PARA A CARACTERIZAÇÃO DE SINAIS  
MIOELÉTRICOS ATRAVÉS DO USO DE REGRESSÃO  
LOGÍSTICA**

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia Elétrica e aprovada em sua forma final pelo Orientador e pela Banca Examinadora.

Orientador: \_\_\_\_\_

Prof. Dr. Alexandre Balbinot, UFRGS  
Doutor pela UFRGS – Porto Alegre, Brasil

Banca Examinadora:

Prof. Dra. Léia Bernardi Bagesteiro, UFABC  
Doutora pela University of Surrey – Surrey, Inglaterra

Prof. Dr. Milton Antônio Zaro, UFRGS  
Doutor pela UFRGS – Porto Alegre, Brasil

Prof. Dr. Altamiro Amadeu Susin, UFRGS  
Doutor pela Institut National Polytechnique de Grenoble – Grenoble, França

Prof. Dra. Ana Carolina Ribeiro Teixeira, UFCSPA.  
Doutora pela UFRGS – Porto Alegre, Brasil.

Coordenador do PPGEE: \_\_\_\_\_

Prof. Dr. Luís Fernando Alves Pereira

Porto Alegre, Janeiro de 2016.

## **DEDICATÓRIA**

Aos meus pais, verdadeiros heróis que diligentemente se esforçam para me fornecer uma formação moral e afetiva e por criarem um lar amoroso, em especial a minha mãe, a mulher mais admirável que já conheci na vida. Sinto-me frustrado por não ser capaz de transliterar o tamanho do meu respeito e admiração a estes dois seres incríveis, saibam que tudo que possivelmente realizarei na vida, possui a marca de vocês.

Aos meus irmãos, por sempre me oportunizarem respirar, pensar na vida e enxergá-la com a simplicidade e inocência de uma criança. Quando menor, costumava achar que excepcional uma palavra pejorativa, hoje em dia entendo seu verdadeiro significado.

Aos tantos bons amigos espalhados pelo mundo tentando torná-lo um lugar melhor, continuem o ótimo trabalho, precisamos de cada vez mais pessoas como vocês.

Aos amigos mais próximos (vocês sabem quem são), verdadeiros irmãos que a vida me deu e que eu não teria como escolher melhor.

A todos que sabem que o extraordinário é algo impossível de ser domado pela tirania da normalidade, em especial, a todos os professores que sempre acreditaram e apoiaram.

A tantos brilhantes que estabeleceram as bases científicas que possibilitam a realização de um trabalho como este e tantos outros que virão e levarão a ciência adiante, consolidando-a como uma ferramenta que possibilite uma vivência mais plena a todos os seres.

## **AGRADECIMENTOS**

Ao professor Dr. Alexandre Balbinot pela orientação paciente e de extrema competência, mas acima de tudo pela confiança depositada.

Aos colegas do PPGEE pelo seu companheirismo e auxílio nas tarefas desenvolvidas durante o curso e apoio na revisão deste trabalho. Em especial aos colegas e amigos do IEE pelo apoio moral e científico em cada etapa deste projeto. Um agradecimento ainda mais especial à colega Gabriela Favieiro pelo companheirismo nas disciplinas, trabalhos desenvolvidos e todo o conhecimento transmitido de forma terna e paciente, sempre com contribuições muito pertinentes que agregaram em muito neste trabalho.

Um agradecimento especial a Sara Borelli, uma das mais gratas surpresas que tive o privilégio de ganhar da vida nos últimos tempos e que foi fundamental no decorrer deste último ano, oferecendo toda a ternura, apoio e companheirismo para o alcance de várias metas, acadêmicas e pessoais e incontáveis momentos de diversão e boas risadas.

Ao Programa de Pós-Graduação em Engenharia Elétrica, pela oportunidade de realização dos trabalhos em minha área de pesquisa bem como a equipe de professores que forneceram muito do subsídio intelectual para a realização deste trabalho.

*“We gotta make a change...  
It's time for us as a people to start makin' some changes.  
Let's change the way we eat, let's change the way we live  
and let's change the way we treat each other.  
You see the old way wasn't working so it's on us to do  
what we gotta do, to survive.”*

TUPAC AMARU SHAKUR

## RESUMO

Através dos dispositivos e técnicas desenvolvidas na área da Instrumentação Biomédica é possível oferecer um tratamento ou de forma geral soluções que permitam uma vivência mais plena em sociedade para pessoas que possuem algum tipo de deficiência ou doença. Com o aumento da capacidade computacional nos últimos anos foi possível desenvolver muitas técnicas e dispositivos apoiados em processamento digital de sinais e há um grande interesse pelo desenvolvimento de interfaces mais naturais, como sinais biológicos para o controle de próteses e dispositivos. Este trabalho tem por objetivo apresentar o desenvolvimento de um método de Inteligência Computacional baseado em Regressão Logística capaz de classificar 17 movimentos do segmento mão-braço realizados pelos voluntários do estudo através do processamento do sinal mioelétrico (SME) adquiridos dos sujeitos em questão. Adicionalmente é realizada uma avaliação da influência de alguns dos canais, características do sinal e movimentos executados na taxa de acerto global. Para a realização do sistema foi utilizado um aparato experimental capaz de adquirir os SME através de 12 canais utilizando eletrodos não invasivos e posteriormente digitalizá-los. Logo após efetua-se a extração das três características utilizadas no trabalho, que servem de entrada para o método de Regressão Logística. Para este estudo foram processados três bancos de dados que perfazem um total de 50 voluntários. A taxa média de acerto alcançada foi de 70,1%, considerando todas as variações de testes realizados enquanto a média para os melhores casos de cada variação de entrada realizada foi de 92,5%.

**Palavras-chaves:** Sinal Mioelétrico. Regressão Logística. Eletromiografia. Instrumentação Biomédica. Movimentos do Membro Superior, Projeto de Experimentos.

## **ABSTRACT**

Through the devices and techniques developed in the field of Biomedical Instrumentation commonly is possible to offer treatment or solutions to provide a more pleasurable experience in society for people who have a disability or illness. With increasing computing capability in recent years, it has been possible to develop many techniques and devices supported by digital signal processing, and there is a great interest in the development of more natural interfaces, such as biological signals for the control of devices and prostheses. This work aims to present the development of a computational intelligence method based on Logistic Regression able to classify 17 movements of the hand-arm segment performed by the subjects of this study through the processing of the myoelectric signal (SME) acquired from the subject in question. Additionally, an assessment of the influence of some of the combination of the channels, signal characteristics and movements performed in the overall hit rate is additionally performed. To conduct the system has built an experimental apparatus able to acquire the SME through 12 channels using non-invasive electrodes and scan them. Thereafter there is a three features extraction from the signal which serves as input to the Logistic Regression method. For this study were processed three databases that compose 50 volunteers. The average hit rate achieved was 70.1%, considering all tests variations while the average for the best cases for each input variation performed was 92,5 %.

**Keywords: Myoelectric Signal. Logistic Regression. Electromyography. Biomedical Instrumentation. Upper-limb Movements, Design of Experiments.**



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>15</b>
1.1	JUSTIFICATIVA	15
1.2	OBJETIVOS	16
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>18</b>
2.1	PRINCÍPIOS BÁSICOS SOBRE SINAIS MIOELÉTRICOS	18
2.1.1	Neurônio Motor e Potencial de Ação	19
2.1.2	Transmissão do Impulso Nervoso	22
2.1.3	Músculo esquelético	24
2.1.4	Potencial da unidade motora	26
2.2	PRINCÍPIOS BÁSICOS SOBRE ELETROMIOGRAFIA	28
2.2.1	Sinal de eletromiografia de superfície (sEMG)	29
2.2.2	Aquisição do sEMG	30
2.2.2.1	Posicionamento dos Eletrodos	31
2.2.2.2	Musculatura do braço	32
<b>3</b>	<b>REGRESSÃO LOGÍSTICA</b>	<b>35</b>
3.1	FUNÇÃO PREDITORA	36
3.2	DISTRIBUIÇÃO DE PROBABILIDADES	38
3.3	ADEQUAÇÃO DOS PARÂMETROS DO MODELO	39
3.3.1	Limiar de decisão	40
3.3.2	Limiar de decisão linear	40
3.3.3	Limiar de decisão não linear	42
3.4	FUNÇÃO CUSTO	43
3.4.1	Método de descida do gradiente	46
3.4.2	Regularização	47
3.5	MÉTODO ONE-VERSUS-ALL (OVA)	50
3.6	TRABALHOS RELACIONADOS À CLASSIFICAÇÃO DE MOVIMENTOS ATRAVÉS DE PROCESSAMENTO DE SINAIS DE SEMG	51
<b>4</b>	<b>METODOLOGIA EXPERIMENTAL</b>	<b>57</b>
4.1	AQUISIÇÃO DE DADOS DA BASE DO LABORATÓRIO IEE	58
4.1.1	Eletromiógrafo e eletrodos	58
4.1.2	Modelo virtual	60
4.1.3	Procedimentos Para a Realização dos Ensaios de Aquisição de Dados	62
4.2	DESCRIÇÃO DA BASE DE DADOS NINAPro	65
4.3	MOVIMENTOS REALIZADOS NOS ENSAIOS	66
4.4	PROCESSAMENTO DOS BIOSINAIS	66
4.4.1	Pré-processamento	67
4.4.1.1	Segmentação da base de dados NinaPro	67
4.4.1.2	Segmentação da base de dados adquirida no Laboratório IEE	68
4.4.1.3	Retificação e normalização do sinal de sEMG	70
4.4.1.4	Extração de características	71
4.4.2	Processamento do sinal de sEMG	73
4.4.2.1	Ajuste dos parâmetros de $\alpha$ e $\lambda$	74
4.4.2.2	Variação dos dados de entrada	77
4.4.2.3	Definição do modelo de Regressão Logística	82

4.4.2.4	Classificação .....	87
4.4.2.5	Tratamento dos dados de saída do sistema .....	89
<b>4.4.3</b>	<b>Validação estatística .....</b>	<b>91</b>
<b>5</b>	<b>RESULTADOS E DISCUSSÕES .....</b>	<b>94</b>
<b>5.1</b>	<b>TAXA DE ACERTO MÉDIO GLOBAL POR MOVIMENTO .....</b>	<b>97</b>
<b>5.2</b>	<b>TAXA DE ACERTO MÉDIO GLOBAL EM FUNÇÃO DA VARIAÇÃO DAS CARACTERÍSTICAS .....</b>	<b>99</b>
<b>5.3</b>	<b>TAXA DE ACERTO MÉDIO GLOBAL EM FUNÇÃO DA VARIAÇÃO DOS CANAIS .....</b>	<b>101</b>
<b>5.4</b>	<b>TAXA DE ACERTO MÉDIO GLOBAL EM FUNÇÃO DA VARIAÇÃO COMBINADA DE MOVIMENTOS (FATOR CONTROLÁVEL A) E CARACTERÍSTICAS (FATOR CONTROLÁVEL C) .....</b>	<b>103</b>
<b>5.5</b>	<b>TAXA DE ACERTO MÉDIO GLOBAL EM FUNÇÃO DA VARIAÇÃO COMBINADA DE MOVIMENTOS (FATOR CONTROLÁVEL A) E CANAIS (FATOR CONTROLÁVEL C) .....</b>	<b>104</b>
<b>5.6</b>	<b>TAXA DE ACERTO MÉDIO GLOBAL EM FUNÇÃO DA VARIAÇÃO COMBINADA DE CARACTERÍSTICAS (FATOR CONTROLÁVEL B) E CANAIS (FATOR CONTROLÁVEL C) .....</b>	<b>106</b>
<b>5.7</b>	<b>TAXA DE ACERTO MÉDIO GLOBAL EM FUNÇÃO DA VARIAÇÃO COMBINADA DE MOVIMENTOS (FATOR CONTROLÁVEL A), CARACTERÍSTICAS (FATOR CONTROLÁVEL B) E CANAIS (FATOR CONTROLÁVEL C) .....</b>	<b>108</b>
<b>5.8</b>	<b>TAXA DE ACERTO MÉDIO POR BASES DE DADOS E ENTRE VOLUNTÁRIOS .....</b>	<b>108</b>
<b>5.9</b>	<b>MELHORES MÉDIAS DE RESULTADOS .....</b>	<b>113</b>
<b>5.10</b>	<b>COMPARAÇÃO DOS RESULTADOS COM TRABALHOS RELACIONADOS DA ÁREA .....</b>	<b>114</b>
<b>6</b>	<b>CONCLUSÕES .....</b>	<b>120</b>
<b>7</b>	<b>RECOMENDAÇÕES PARA TRABALHOS FUTUROS .....</b>	<b>124</b>
	<b>APÊNDICE A - PROGRAMAÇÃO REALIZADA EM LABVIEW PARA AS ETAPAS DE TREINO E AQUISIÇÃO DE DADOS .....</b>	<b>133</b>
	<b>APÊNDICE B - TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO .....</b>	<b>134</b>
	<b>CONSENTIMENTO LIVRE E ESCLARECIDO .....</b>	<b>135</b>
	<b>APÊNDICE C - ANAMNESE .....</b>	<b>136</b>

## LISTA DE ILUSTRAÇÕES

Figura 1 Neurônio motor (adaptado livremente de TORTORA, 2007). .....	20
Figura 2 Membrana Celular e potenciais em vista: a) lateral e b) superior (Adaptado livremente de BRONZINO & ENDERLE, 2007). .....	21
Figura 3 Potenciais de ação envolvidos no processo de geração de sinais mioelétricos (Adaptado livremente de TORTORA, 2007). .....	22
Figura 4 Placa Motora (adaptado livremente de GUYTON, 2006). .....	23
Figura 5 Estrutura do Músculo Esquelético (BELTRAMINI, 1999). .....	24
Figura 6 Constituição das fibras musculares esqueléticas (GUYTON, 2006). .....	25
Figura 7 Unidade Motora (Livremente adaptado de STARR & MCMILAN, 2015). .....	27
Figura 8 Formação do SME (Livremente adaptado de BASMAJIAN & DE LUCA, 1985). ..	28
Figura 9 Segmento da série de sEMG do primeiro voluntário da base NinaPro. ....	30
Figura 10 Espectro de potência do segmento de série de sEMG apresentado na Figura 9. ....	30
Figura 11 Influência do posicionamento de eletrodos no sEMG (adaptado livremente de DE LUCA, 1997). .....	32
Figura 12 Principais músculos superficiais do braço e antebraço sEMG (TORTORA, 2007). .....	34
Figura 13 Modelo de regressão linear utilizado como classificador onde a área em azul corresponde à saída positiva ( $Y=1$ ). (Adaptado livremente de NG, 2014). .....	37
Figura 14 Erro de classificação causado em função da nova entrada, parte dos dados é erroneamente classificada como “falsa” ( $Y=0$ ). (Adaptado livremente de NG, 2014). .....	38
Figura 15 Função logística. ....	39
Figura 16 Dados de exemplo para definição de limiar de decisão linear. ....	40
Figura 17 Limiar de decisão linear. ....	41
Figura 18 Dados de exemplo para definição de limiar de decisão não linear. ....	42
Figura 19 Limiar de decisão não linear calculado. ....	43
Figura 20 Custo em função da saída predita para os casos de sucesso ( $y=1$ ) em azul e falha ( $y=0$ ), em vermelho. ....	46
Figura 21 Exemplo de aplicação do OVA para a separação de dados em três classes distintas, para cada classe apresentada em (a) há a geração de um modelo: (b) representa a classe 1 (triângulos); (b) representa a classe 2 (quadrados) e (c) a classe 3 (x). Em cada modelo é calculada a probabilidade do dado pertencer àquele modelo contra a probabilidade de pertencer a qualquer outro. (Adaptado livremente de NG, 2014). .....	50
Figura 22 Diagrama de blocos do sistema proposto. ....	57
Figura 23 Foto Arranjo experimental utilizado na aquisição dos sinais: (1) monitor para a visualização dos movimentos; (2) arranjo dos dois eletromiógrafos utilizados; (3a, 3b e 3c) Cabos do eletromiógrafo: (a) 4 canais para posicionamento específico, (b) 8 canais para posicionamento aleatório e (c) eletrodos de referência; (4) eletrodos de superfície utilizados; (5) placa digitalizadora; (6) borneira e (7) computador utilizado. ....	59
Figura 24 Fluxograma da rotina de visualização das animações e aquisição de dados. ....	62
Figura 25 Foto do posicionamento dos eletrodos. ....	64

Figura 26 Foto da realização de um dos ensaios. ....	65
Figura 27 Movimentos alvo de classificação (adaptado livremente de ATZORI, 2014). ....	66
Figura 28 Segmentação e extração de características do sinal. ....	68
Figura 29 Exemplo do procedimento de segmentação baseada em <i>timestamp</i> . ....	69
Figura 30 Exemplo de parte de um arquivo de dados adquirido e o tratamento de dados utilizado na segmentação por timestamp: a) sinal de sEMG após a segmentação, b) sinal de sEMG após a segmentação e retificação, c) sinal de sEMG após a segmentação, retificação e normalização. ....	71
Figura 31 Extração da frequência mediana da janela de segmentação. ....	72
Figura 32 Diagrama de blocos simplificado do programa desenvolvido. ....	73
Figura 33 Exemplo de variação do parâmetro alpha. ....	74
Figura 34 Exemplo de variação do parâmetro lambda. ....	75
Figura 35 Fluxograma da função <i>Main_test</i> . ....	78
Figura 36 Fluxograma da função de ordenação dos dados de entrada. ....	80
Figura 37 <i>k-fold</i> realizado. ....	81
Figura 38 Fluxograma da função responsável pelo <i>k-fold</i> . ....	81
Figura 39 Fluxograma da função <i>LR</i> . ....	82
Figura 40 Valores de RMS do canal 1 do voluntário 1 da base NinaPro: a) Não-normalizados e b) normalizados. Os valores apresentados são relativos ao $k=1$ do <i>k-fold</i> . ....	83
Figura 41 Decréscimo da função custo (erro) do sistema até a décima iteração entre saída prevista e saída testada pelo classificador no processo de otimização matemática. ....	83
Figura 42 Fluxograma da função <i>LR_coef_calc</i> . ....	84
Figura 43 Fluxograma da função <i>LR_result_calc</i> . ....	85
Figura 44 Probabilidades a posteriori calculadas para uma instância do <i>k-fold</i> para o voluntário 1 da base de dados NinaPro. ....	86
Figura 45 Probabilidades: colunas em vermelho representado a classe 1 e colunas em laranja representando a classe 2 de movimentos. ....	87
Figura 46 Fluxograma da classificação de movimentos. ....	88
Figura 47 Fluxograma da função <i>accuracy_calc</i> . ....	89
Figura 48 Matriz de confusão gerada pelo sistema para a condição de uso de todos canais e características para o voluntário 1 da base de dados NinaPro não-amputados. Nela é possível visualizar: a taxa de acerto global (fundo preto), a taxa de acerto individual de cada movimento (diagonal principal em fundo verde), as taxas de falso positivo, verdadeiro positivo, falso negativo e verdadeiro negativo (expostos em fundo azul) e quais movimentos foram confundidos em caso de erro (fundo vermelho na mesma coluna do movimento). ....	90
Figura 49 Fluxograma da função <i>result_eval</i> . ....	91
Figura 50 Taxa de acerto médio global para cada movimento realizado. ....	97
Figura 51 Taxa de acerto médio global em função da variação de características. ....	99
Figura 52 Taxa de acerto médio global em função da variação dos canais. ....	101
Figura 53 Influência dos canais e movimentos na taxa de acerto médio. ....	105
Figura 54 Influência dos canais e características utilizados na taxa de acerto. ....	107
Figura 55 Comparação entre as bases de dados utilizadas neste estudo. ....	110
Figura 56 Taxas de acerto global para os voluntários da base NinaPro Não Amputados. ....	111
Figura 57 Taxas de acerto global para os voluntários da base IEE. ....	112
Figura 58 Taxas de acerto global para os voluntários da base NinaPro Amputados. ....	113

## LISTA DE TABELAS

Tabela 1 Principais músculos superficiais do braço e antebraço e suas funções. ....	33
Tabela 2 Características extraídas para o uso na classificação e caracterização de movimentos. .....	53
Tabela 3 Divisão dos grupos de dados utilizados na classificação de movimentos. ....	67
Tabela 4 Valores de alpha e lambda obtidos para os voluntários.....	76
Tabela 5 Matriz 102x36 representativa de entrada para a etapa de treinamento da regressão logística: em verde a seção de 102x12 correspondente a característica RMS, em amarelo a seção de mesmo tamanho representando a variância e em azul a última seção representando a frequência mediana para todos os movimentos realizados..	78
Tabela 6 Combinações de características de entradas utilizadas.....	79
Tabela 7 Combinações de canais de sEMG utilizados para cada entrada gerada pela variação das características de entrada utilizadas.....	79
Tabela 8 Projeto de Experimentos realizado baseado nos resultados de classificação. ....	92
Tabela 9 Cálculo do Projeto de Experimentos realizado.....	94
Tabela 10 Posicionamento dos eletrodos utilizados em relação a musculatura .....	95
Tabela 11 Principais músculos superficiais do braço e antebraço e suas funções. ....	96
Tabela 12 Melhores médias para cada movimento.....	114
Tabela 13 Médias gerais por base nos melhores casos.....	114
Tabela 14 Trabalhos Relacionados na área de processamento de sEMG.....	115

## LISTA DE ABREVIATURAS

AG: Algoritmos Genéticos

ANOVA: *Analysis of Variance*

CVM: Contração Voluntária Máxima

DC: Corrente Contínua

EEG: Eletroencefalografia

EMG: Eletromiografia/Sinal Eletromiográfico

FFT: *Fast Fourier Transform*

FIR: *Finite Input Response*

FL: *Fuzzy Logic*

fMED: Frequência Mediana

FP: Função Preditora

GDL: Graus de Liberdade

IC: Inteligência Computacional

ICA: *Independent Component Analysis*

IEE: Laboratório de Instrumentação Eletro-Eletrônica

LDA: *Linear Discriminant Analysis*

LSE: *Least Square Error*

MUAP: *Motor Unit Action Potential*

MUAPT: *Motor Unit Action Potential Train*

n.a.: Não Amputados

NinaPro: *Non-Invasive Adaptive Hand Prosthetics*

OVA: *One-Versus-All*

PCA: *Principal Component Analysis*

PPGEE: Programa de Pós-Graduação em Engenharia Elétrica

RB: Redes Bayesianas

RL: Regressão Logística

RLB: Regressão Logística Binomial

RLM: Regressão Logística Multinomial

RMS: *Root Mean Square*

RNA: Redes Neurais Artificiais

sEMG: Eletromiografia de Superfície

SME: Sinal Mioelétrico

STFT: *Short-Time Fourier Transform*

STTT: *Short-Time Thompson Transform*

SVM: *Support Vector Machine*

UFRGS: Universidade Federal do Rio Grande do Sul

VAR: Variância

## **1 INTRODUÇÃO**

Pesquisas direcionadas à área da Instrumentação Biomédica objetivam proporcionar uma melhor qualidade de vida a um indivíduo, possibilitando uma vivência mais plena em sociedade. Por ser uma área multidisciplinar, pesquisas direcionadas a este enfoque estão em franca expansão, valendo-se de outros avanços em áreas como instrumentação inteligente, microeletrônica, medicina, física, química e outros campos de estudos correlatos (BRONZINO & ENDERLE, 2012; ENDERLE, 2006). Portanto, através dos estudos desenvolvidos nessa área é possível compensar alguma deficiência do corpo humano, seja ela congênita ou adquirida ao longo da vida. Desse grande campo de estudo, derivam técnicas destinadas a outorgar maior independência a portadores de limitações físicas. Duas grandes áreas de estudo que tem se mostrado bastante promissoras pelos seus desenvolvimentos recentes são a Eletromiografia (EMG) e Eletroencefalografia (EEG) (BRONZINO & ENDERLE, 2012; MOORE & ZOURIDAKIS, 2004). Com este mesmo enfoque, o uso de técnicas de inteligência computacional e instrumentação inteligente permitem suprir tão bem quanto possível as funcionalidades de alguma parte deficiente do corpo do sujeito em questão e, desta forma, promover a sua reinserção autônoma na sociedade (BRONZINO & ENDERLE, 2012).

### **1.1 JUSTIFICATIVA**

Evidenciado o enfoque das pesquisas direcionadas à área de Instrumentação Biomédica, fica nítida a capacidade de influenciar de forma positiva a vida das pessoas e da capacidade de integrá-las à sociedade para uma vivência mais plena.

Comumente, as soluções oferecidas baseiam-se no uso de próteses mecânicas capazes de realizar poucos movimentos e que contemplam poucos graus de liberdade. Recentemente, houve um aumento no interesse pela utilização de próteses biomecânicas interfaceadas a



biosinais, que tem sido utilizadas a fim de propiciar uma experiência mais plena e natural aos usuários (BRONZINO & ENDERLE, 2012; MOORE & ZOURIDAKIS, 2004). O emprego de sinais biológicos para a interação com estas próteses, oferece uma interface mais intuitiva e natural para o controle do usuário. Portanto, é de extremo interesse o desenvolvimento de interfaces entre estes sinais biológicos e estas próteses para uma experiência mais plena em relação à utilização de próteses por parte dos usuários.

## **1.2 OBJETIVOS**

O objetivo principal deste trabalho consiste no desenvolvimento de um método de inteligência computacional que possibilite a realização de uma interface humano-computador de forma a prover uma possibilidade de classificação de movimentos realizados por um indivíduo através do processamento do sinal mioelétrico (SME) adquirido do sujeito em questão.

Para realizar a caracterização dos movimentos, foi desenvolvido um método de inteligência computacional baseado na técnica de Regressão Logística, que embora seja uma técnica muito utilizada em ciências sociais aplicadas, ainda não possui um uso muito difundido entre o presente tipo de estudo. Esta técnica visa utilizar características extraídas dos sinais eletromiográficos para interpretar a intenção de movimento do sujeito. Em função disso, o método computacional empregado deve ser capaz de classificar movimentos escolhidos do segmento mão-braço contemplando diversos graus de liberdade.

A saída do sistema proposto consiste em um dos 17 movimentos escolhidos para o estudo e a figura de mérito do método consiste na taxa de acerto na classificação dos movimentos. De tal forma que, o método se mostre tanto eficiente quanto sua taxa de acerto dos movimentos.

Os objetivos específicos deste trabalho são: a) realizar uma avaliação da influência do número e combinação de alguns dos canais e características comumente utilizadas no processamento de sinais de eletromiografia, que são utilizados como entrada do método de Regressão Logística e b) estabelecer uma relação entre taxa de acerto individual para cada movimento, bem como, para a taxa de acerto global e a influência de cada movimento nesta taxa, testando o desempenho do método de regressão logística nesta aplicação específica.

## 2 REVISÃO BIBLIOGRÁFICA

### 2.1 PRINCÍPIOS BÁSICOS SOBRE SINAIS MIOELÉTRICOS

Em 1791, Luigi Galvani publicou seu trabalho intitulado “*De Viribus Electricitatis In Motu Musculari*” através da Academia de Ciência de Bolonha. Esta célebre publicação descrevia o trabalho de Galvani e descoberta da existência de atividade elétrica em um animal. Na época de sua publicação, este artigo causou um grande impacto na Comunidade Científica e gerou uma polêmica que culminou com a criação do campo de estudo da eletrofisiologia. Após esta publicação, surgiram diferentes interpretações dos dados apresentados. Por exemplo, Galvani estava convencido de que as contrações musculares que observou em seus experimentos, utilizando pernas de rã, foram ocasionadas por alguma forma de Energia Elétrica proveniente do animal. Por outro lado, Allessandro Volta, na época professor de física na Universidade de Pádua, estava convencido de que a "Eletricidade" descrita nos experimentos de Galvani não emanava do animal, mas surgia em consequência do uso de metais diferentes utilizados nas experiências de Galvani (BRONZINO & ENDERLE, 2012).


Diversos estudos emanaram das duas vertentes de pensamento; Entre eles, é importante citar o trabalho realizado em 1838 por Carlos Mateucci, que utilizando um galvanômetro realizou experiências com sapos com nervos intactos. Mateucci provou que a contração muscular era estimulada a partir de um toque no nervo, demonstrando assim, a existência de atividade elétrica durante a contração muscular (MALMIVUO & PLONSEY, 1995). Outro trabalho igualmente relevante foi realizado em 1849, por Frenchman Dubois-Reymond, que através de um experimento prático, detectou um sinal elétrico concomitante ao movimento voluntário do braço de um voluntário do experimento. Desse experimento, foi concluído que a contração de um músculo constitui o reflexo involuntário da passagem de

corrente elétrica por suas fibras musculares. Esta corrente é denominada de sinal mioelétrico (MEULDERS *et al.*, 2013).

No Século XX, as pesquisas tiveram como foco o estudo da morfologia dos sinais mioelétricos. Estas pesquisas possibilitaram o surgimento da eletromiografia (EMG), onde se utilizavam eletrodos específicos para captar os sinais mioelétricos do corpo de um sujeito e apresenta-los na tela de um osciloscópio analógico. Herbert Gasser e Joseph Erlanger foram os pioneiros nos estudos da morfologia do sinal mioelétrico, o que lhes rendeu o Prêmio Nobel de Medicina em 1944 (CRAM, 2003). É interessante notar que a contração muscular consiste na contração involuntária do músculo quando exposto a um determinado potencial que não é gerado localmente e sim por um neurônio motor. Posteriormente o potencial elétrico passa pela etapa de transmissão sináptica, os potenciais de ação dos respectivos músculos se somam e assim compõem o sinal mioelétrico, o que ocasiona a contração das fibras musculares (BRONZINO & ENDERLE, 2007; GUYTON, 2006).

### **2.1.1 Neurônio Motor e Potencial de Ação**

A célula nervosa motora (neurônio motor) é limitada por uma membrana adaptada de modo específico para a transmissão de sinais neurais. O neurônio motor é responsável por comandar diretamente a contração das fibras musculares. A membrana que delimita o neurônio possui uma diferença de potencial elétrico entre o interior e exterior da célula mesmo em repouso. Este potencial de repouso da membrana é permanentemente afetado por várias trocas celulares. Quando certo potencial é alcançado, um potencial de ação é gerado ao longo do seu axônio para todas as suas conexões distantes até as vesículas sinápticas, que quando estimuladas pelo botão sináptico, fazem o neurônio liberar neurotransmissores através de sinapses, o que possibilita que o impulso gerado seja transmitido (BRONZINO & ENDERLE, 2012). O neurônio motor é apresentado na Figura 1.

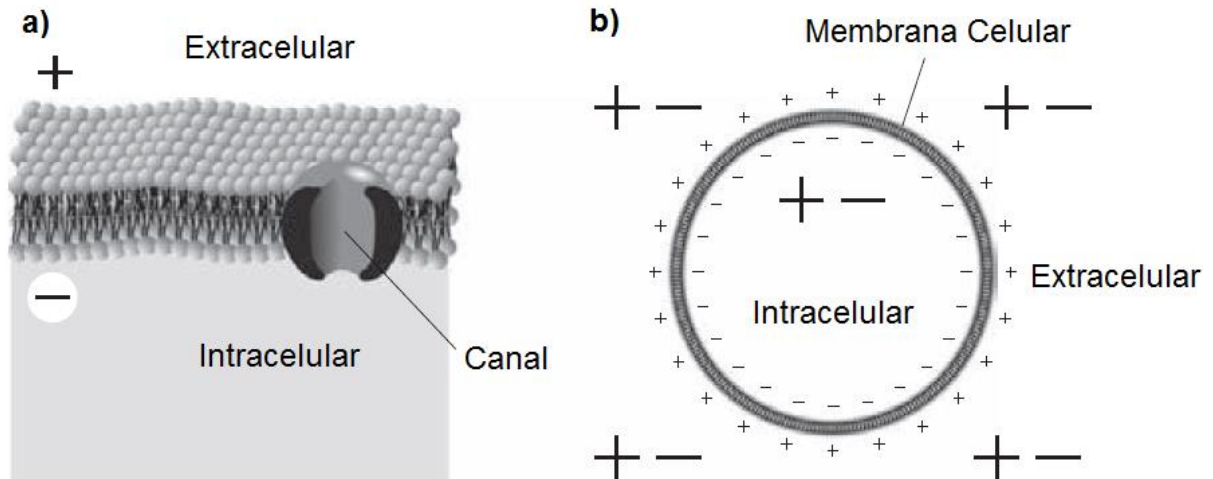


**Figura 1 Neurônio motor (adaptado livremente de TORTORA, 2007).**

O potencial de ação neural realiza a propagação do impulso nervoso nos neurônios através de reações eletroquímicas. Logo que um sinal é transmitido ao longo de uma fibra nervosa, ocorrem variações de cargas em relação ao potencial da membrana, sendo essas variações denominadas de potencial de ação (GUYTON, 2006).

As separações de carga, devido à permeabilidade seletiva da membrana aos íons, são responsáveis pela diferença de potencial da membrana. No neurônio, a diferença de potencial através da membrana celular é de cerca de 60mV a 90mV, dependendo da célula. Por convenção, o exterior é definido como 0V (referência), e o potencial de repouso varia entre -60mV e -90mV. Esta diferença de potencial é de particular interesse, uma vez que a maior parte da geração de sinais envolve mudanças neste potencial através da membrana. Sinais,

como potenciais de ação são o resultado de perturbações elétricas na membrana (BRONZINO & ENDERLE, 2012). A representação simplificada da membrana de uma célula genérica de exemplo e seus potenciais são ilustrados na Figura 2 e os potenciais de ação envolvidos no processo de geração do sinal mioelétrico são detalhados a seguir.

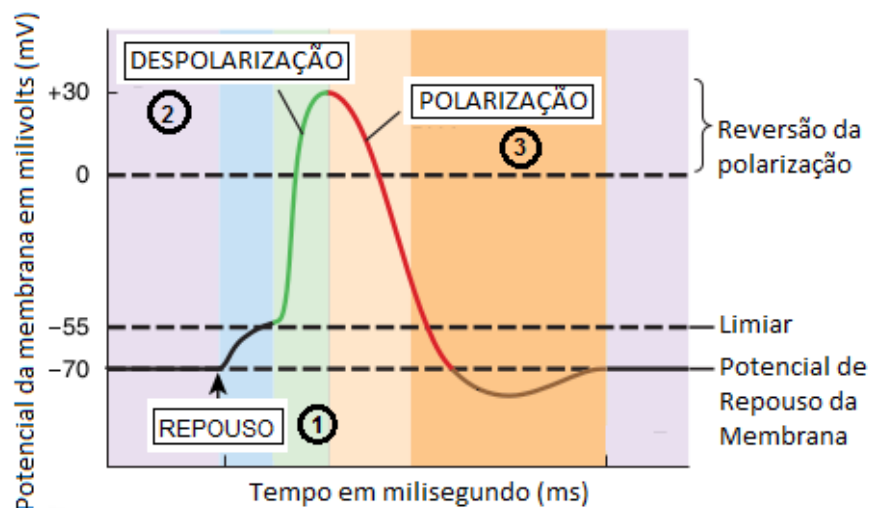


**Figura 2 Membrana Celular e potenciais em vista: a) lateral e b) superior (Adaptado livremente de BRONZINO & ENDERLE, 2007).**

O potencial de ação é gerado quando ocorre uma mudança abrupta no potencial de repouso negativo da membrana, tornando-se positivo, e, em seguida, terminando, quando o potencial da membrana volta para seu potencial negativo. Segundo (BRONZINO & ENDERLE, 2012) e (GUYTON, 2006), as três principais etapas da geração do potencial da membrana e na transmissão do impulso nervoso são:

- 1) **Estado de repouso:** a membrana é quase impermeável aos íons de sódio ( $\text{Na}^+$ ) e bastante permeável aos íons de potássio ( $\text{K}^+$ ). Isto provoca a difusão de íons de  $\text{K}^+$  do interior da fibra muscular para o seu exterior. Os íons de potássio têm carga positiva e como consequência o exterior da membrana é carregado positivamente. Após a difusão do  $\text{K}^+$ , no interior da fibra permanecem moléculas de proteínas, portadoras de carga negativa, gerando um potencial de membrana negativo, por volta de  $-60\text{mV}$  a  $-90\text{mV}$ ;

- 2) **Despolarização:** ao sofrer um estímulo, a membrana se torna permeável aos íons de  $\text{Na}^+$ , iniciando o potencial de ação. Ao ocorrer este processo, os íons de  $\text{Na}^+$  fluem rapidamente para o interior da fibra, tornando o potencial da membrana celular positivo;
- 3) **Repolarização:** o processo de repolarização ocorre devido à polaridade positiva interna da membrana coibir o fluxo contínuo de  $\text{Na}^+$  para o seu interior, o que torna a membrana novamente impermeável aos íons de  $\text{Na}^+$  (ao mesmo tempo em que continua impermeável aos íons de  $\text{K}^+$ ). Os íons de potássio ( $\text{K}^+$ ), agora em alta concentração no interior da membrana, difundem-se para o exterior levando consigo cargas positivas, o que deixa o potencial da membrana negativo novamente e torna a membrana apta a transmitir um novo impulso nervoso. A Figura 3 representa uma série completa composta pelos diferentes potenciais de ação.




**Figura 3** Potenciais de ação envolvidos no processo de geração de sinais mioelétricos (Adaptado livremente de TORTORA, 2007).

### 2.1.2 Transmissão do Impulso Nervoso

A interface entre a fibra muscular esquelética e os terminais do axônio ocorre na placa motora. Na placa motora a fibra nervosa se ramifica próximo ao seu término para formar uma

rede de terminais que são mergulhados na goteira sináptica, separados pela fenda sináptica em um espaçamento de cerca de 20 a 30nm, processo esse demonstrado na Figura 4.



**Figura 4 Placa Motora (adaptado livremente de GUYTON, 2006).**

No fundo da goteira, existem as fendas subneurais, que aumentam a superfície de atuação do transmissor sináptico e contém agregados da enzima colinesterase, que é capaz de destruir a acetilcolina (neurotransmissor sintetizado nos terminais dos axônios a partir da colina e da acetilcoenzima). O terminal axônico possui grande concentração de mitocôndrias que fornecem energia principalmente para a síntese de acetilcolina, agente excitador das fibras musculares. A acetilcolina é armazenada nas vesículas sinápticas e também encontrada em grande quantidade no terminal axônico (GUYTON, 2006).


Ao chegar à placa motora, um impulso nervoso provoca a liberação do transmissor acetilcolina nas fendas sinápticas. A acetilcolina por sua vez, atua sobre as pregas da membrana muscular, provocando o aumento da sua permeabilidade aos íons de sódio ( $\text{Na}^+$ ). Este processo possibilita a passagem instantânea de sódio para o interior da fibra muscular, o que causa a despolarização da membrana muscular. A despolarização da membrana causa um potencial de ação que se propaga nas duas direções da fibra muscular, o que causa a sua contração (GUYTON, 2006; BRONZINO & ENDERLE, 2012).



Após a liberação da acetilcolina ela é transformada em ácido acético e colina por ação da colinesterase, que é liberada nas pregas subneurais. A destruição da acetilcolina acarreta na repolarização da membrana, que diminui sua permeabilidade ao sódio e fica pronta para receber um próximo estímulo (GUYTON, 2006).

### 2.1.3 Músculo esquelético


O músculo esquelético é um aglomerado de fascículos musculares, que por sua vez são compostos por numerosas fibras musculares com o formato de cilindro e diâmetro entre 10 e 80 micras, conforme esboço da Figura 5 (BELTRAMINI, 1999). Por sua vez, cada fibra muscular é formada por unidades progressivamente menores chamadas respectivamente de: miofibrilas, núcleo celular e retículo sarcoplasmático. Estas estruturas são envoltas por uma membrana chamada de sarcolema (BELTRAMINI, 1999).



**Figura 5 Estrutura do Músculo Esquelético (BELTRAMINI, 1999).**

O retículo sarcoplasmático apresenta grande concentração de íons de Cálcio ( $\text{Ca}^{++}$ ) que são liberados durante o processo de contração muscular. As proteínas de miosina

(miofilamentos espessos) e actina (miofilamentos delgados), por sua vez, compõe os miofilamentos que constituem as miofibrilas, conforme mostra a Figura 6 (GUYTON, 2006).



**Figura 6** Constituição das fibras musculares esqueléticas (GUYTON, 2006).

Os miofilamentos dos sarcômeros localizados nas fibras musculares são os constituintes das unidades funcionais básicas das fibras musculares estriadas. Os sarcômeros são separados entre si por zonas estreitas denominadas de discos Z. Um sarcômero é

constituído por duas diferentes bandas. Uma banda A, que contém principalmente miofilamentos espessos (zona H no centro de cada banda A concentra exclusivamente miofilamentos espessos) e uma banda I (composta por miofilamentos delgados). O aspecto estriado da fibra muscular nada mais é do que a combinação destas duas bandas alternadas. (TORTORA, 2007).

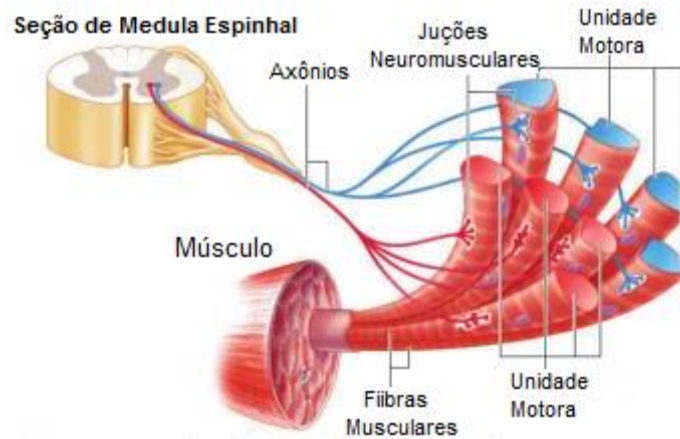
Ao percorrer uma fibra muscular, um potencial de ação provoca alterações na permeabilidade da membrana do retículo sarcoplasmático e uma grande quantidade de cálcio difunde-se para o citoplasma. O cálcio no citoplasma forma um complexo com as proteínas miosina e actina, que sofrem uma ação de atração, o que provoca a contração das miofibrilas e consequentemente a contração muscular. A contração permanece ativa enquanto o potencial de ação permite a difusão de cálcio no citoplasma. Uma vez cessado o estímulo, a contração é cessada (GUYTON, 2006).

#### **2.1.4 Potencial da unidade motora**

A medula espinhal possui derivações que culminam em uma fibra nervosa motora, responsável por inervar numerosas fibras musculares (TORTORA, 2007). Este conjunto, quando inervado por uma só fibra nervosa motora, compõe a unidade motora (ver a Figura 7).

De forma geral, músculos pequenos que exigem controle mais preciso, têm unidades motoras com poucas fibras musculares. De forma contrária, músculos grandes que não precisam de controle muito exato, podem ter unidades motoras com várias centenas de fibras musculares (MCLESTER & St. Pierre, 2007). As fibras musculares de uma unidade motora ficam dispersas por todo o músculo, em microfeixes de 3 a 15 fibras e apresentam-se intercaladas com outras fibras de diversas unidades motoras. Esta disposição permite o funcionamento conjunto das unidades motoras, que não agem como segmentos isolados. No

início da contração muscular poucas unidades motoras são recrutadas e à medida que o músculo é mais solicitado mais unidades motoras são utilizadas (GUYTON, 2006).

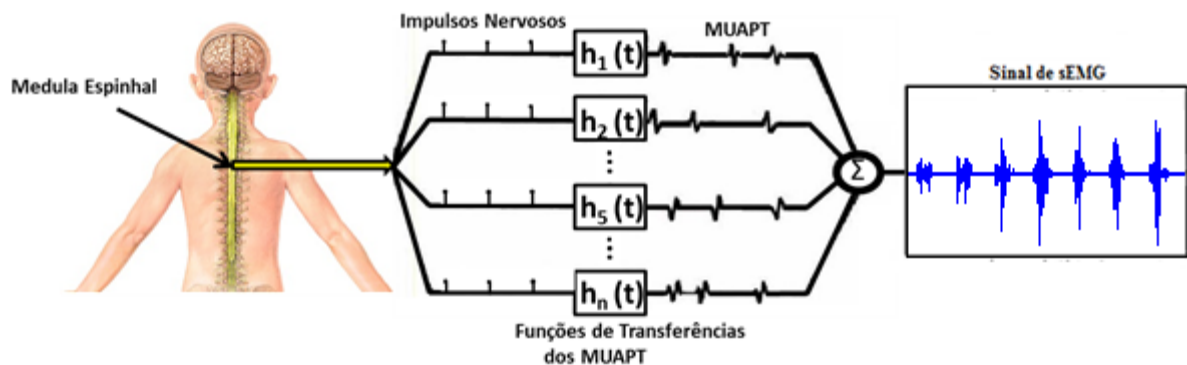


**Figura 7 Unidade Motora (Livremente adaptado de STARR & MCMILAN, 2015).**

A força resultante (tensão muscular) de um movimento muscular depende tanto do número de unidades motoras recrutadas quanto da frequência de estimulação de uma unidade motora. À medida em que esta frequência aumenta, ocorre uma sobreposição de contrações quando uma nova contração ocorre antes do término da precedente. Conseqüentemente, a segunda contração é parcialmente somada à anterior, promovendo um aumento progressivo da tensão muscular da contração proporcional à intensidade da frequência de estimulação. Em um nível crítico, as contrações sucessivas tornam-se tão rápidas que se fundem entre si, e a contração aparece como uniforme e contínua, o que é chamado de tetanização (GUYTON, 2006).

Na ocorrência de um potencial de ação, todas as fibras musculares da sua unidade motora não são estimuladas simultaneamente. A não sincronia do estímulo da unidade motora se deve a dois fatores: a diferença dos tempos de propagação das várias ramificações dos axônios no neurônio motor e a natureza aleatória das descargas de acetilcolina nas junções neuromusculares responsáveis pelo processo de despolarização (GUYTON, 2006).

A soma algébrica resultante dos potenciais de ação nas fibras de uma unidade motora é denominada potencial de ação da unidade motora, abreviada em inglês por MUAP (*Motor Unit Action Potential*). Para sustentar uma contração muscular por períodos prolongados, diversas sequências de MUAPs devem ser ativadas repetidamente, o que ocorre pelo MUAP ter um período relativamente pequeno (2 a 10ms). A essa sequência de MUAPs é dado o nome de trem de potenciais de ação da unidade motora, abreviada em inglês por MUAPT (*Motor Unit Action Potential Train*) (BRONZINO & ENDERLE, 2012; GUYTON, 2006). A Figura 8 apresenta a formação do sinal mioelétrico através da superposição dos MUAPTs provenientes dos potenciais de ação dos neurônios motores.



**Figura 8** Formação do SME (Livrentemente adaptado de BASMAJIAN & DE LUCA, 1985).

Considerando que os músculos contêm fibras musculares de várias unidades motoras, a captação de um MUAPT isolado só pode ser obtida se forem recrutadas apenas fibras de uma única unidade motora na vizinhança do eletrodo. O que segundo (ORTOLAN, 2002), só ocorre em contrações musculares muito fracas.

## 2.2 PRINCÍPIOS BÁSICOS SOBRE ELETROMIOGRAFIA

A atividade muscular elétrica se mostra adequada para o controle de próteses em sujeitos com amputações de caráter trans-radial (NAIK & DINESH, 2012; PHINYOMARK *et al.*, 2012; LI *et al.*, 2011; YOUNG *et al.*, 2012). Toda vez que os potenciais de ação percorrem as fibras musculares um campo eletromagnético é criado em função destas

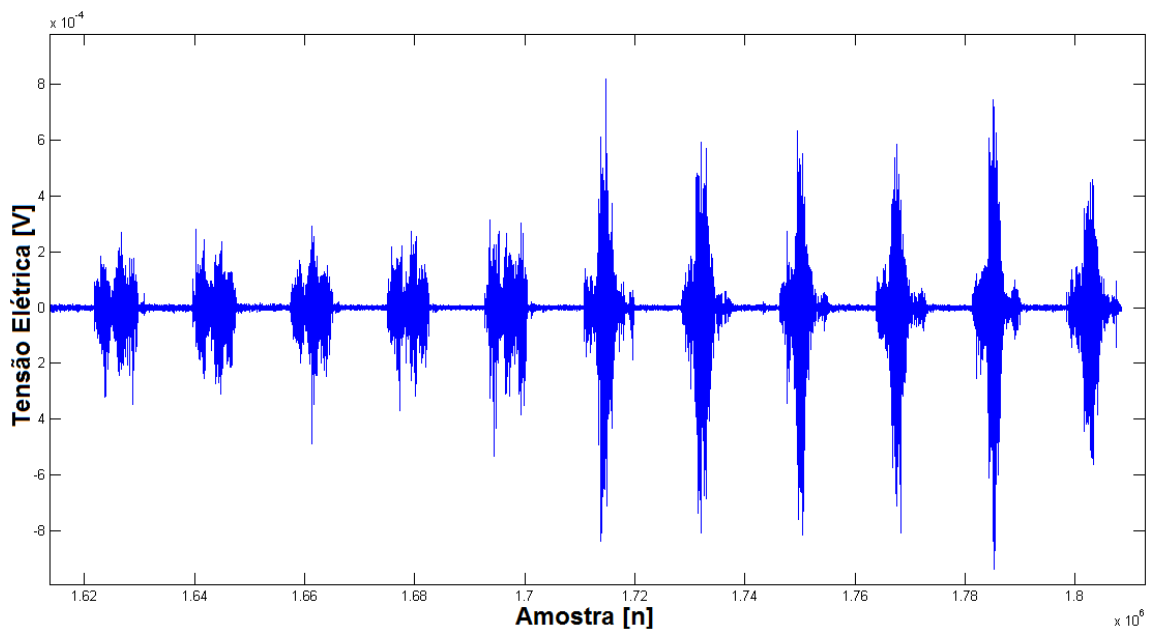
correntes. A eletromiografia tem por objetivo, medir a intensidade desses campos de forma a relacioná-los com atividades elétricas musculares (SMEs). A detecção desses campos eletromagnéticos é realizada através do uso de diferentes tipos de eletrodos.

### **2.2.1 Sinal de eletromiografia de superfície (sEMG)**


A eletromiografia de superfície consiste em um método não invasivo de aquisição dos sinais elétricos oriundos da musculatura ativada para realizar um determinado movimento. Sinais adquiridos através de eletromiografia de superfície (sEMG) durante atividades musculares possuem uma ampla gama de aplicações em Instrumentação Biomédica, Biomecânica, Medicina, entre outras aplicações (BENEDETTI, 2001; MICERA *et al.*, 2000 ; LINS *et al.*, 2015; LIU, 2010).

Pelo fato de o sinal ser adquirido na superfície da pele, comumente são captadas influências de outros grupos musculares, o que influencia fortemente a leitura efetuada e contribui em muito para a aleatoriedade do sinal (TORTORA, 2007). Naturalmente, o sinal eletromiográfico (EMG), possui natureza estocástica, tendo sua amplitude compreendida em uma faixa de 0-10mV e sua frequência na faixa de 15-500 Hz (ATZORI, 2012). Como exemplo, a Figura 9 ilustra dois movimentos – desvio ulnar do pulso e extensão do pulso com mão fechada, respectivamente – do sEMG do primeiro voluntário da base de dados NinaPro.

Já a Figura 10 apresenta a distribuição espectral do mesmo segmento de sinal (obtida através de DFT). Apesar da distribuição espectral relevante para SME ocorrer em uma margem de 15-450 Hz (JIANG, 2014), visualmente é nítida a concentração da potência do sinal na faixa de 50-250 Hz para o segmento de sinal considerado. Estes valores variam - entre outros fatores - de acordo com o tipo de músculo analisado, o nível de contração muscular e o posicionamento dos eletrodos (DE LUCA *et al.*, 2010).



**Figura 9** Segmento da série de sEMG do primeiro voluntário da base NinaPro.



**Figura 10** Espectro de potência do segmento de série de sEMG apresentado na Figura 9.

### 2.2.2 Aquisição do sEMG

A aquisição dos sEMG pode ser realizada por diferentes tipos de eletrodos dependendo da parte do corpo e da musculatura de interesse. A morfologia e a amplitude do SME são dependentes das propriedades elétricas e posicionamento dos eletrodos e do músculo onde a diferença de potencial é medida (DE LUCA *et al.*, 2010; ISON &

ARTEMIADIS, 2014). Existem duas configurações básicas para a utilização dos eletrodos: monopolar e bipolar. Na configuração monopolar são utilizados dois eletrodos onde um deles é considerado a referência e a leitura é dada pela diferença de potencial entre eletrodos. Já na configuração bipolar são utilizados três eletrodos, onde ocorre a leitura de cada um dos eletrodos em relação à referência e a posterior subtração entre estes sinais, este método possibilita uma leitura mais robusta em relação ao ruído do sistema. Os eletrodos são divididos basicamente em invasivos e não invasivos, estes últimos também chamados de eletrodos de superfície (BRONZINO & ENDERLE, 2012).

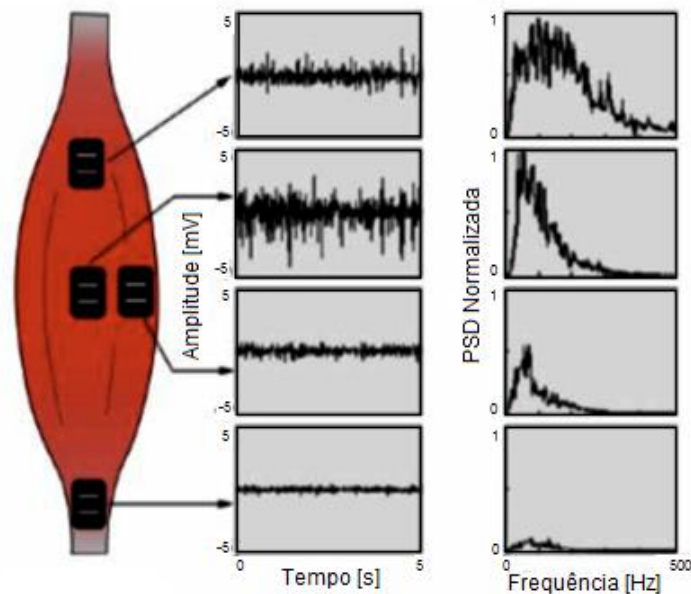
### **2.2.2.1 Posicionamento dos Eletrodos**

A baixa amplitude do SME capturada pelos eletrodos de superfície faz com que o posicionamento dos eletrodos seja uma etapa da máxima importância na aquisição do sinal. Segundo (BASMAJIAN & DE LUCA, 1985) os eletrodos devem ser posicionados na parte ventral do músculo, devido à maior concentração de unidades motoras nessas áreas em relação a áreas marginais. Outro cuidado importante é evitar as extremidades do músculo, onde outros grupos musculares podem exercer demasiada influência. Com o objetivo de ilustrar, a Figura 11 representa a influência do posicionamento dos eletrodos no sinal adquirido em relação a sua amplitude e Densidade Espectral de Potência (do inglês, PSD) normalizada.

Segundo (DE LUCA, 1997; ISON *et al.*, 2014), existem alguns cuidados que contribuem para uma melhor aquisição do SME: (a) a escolha de eletrodos de tamanho adequado, tendo uma fixação mais precisa em relação ao músculo e diminuindo o *cross-talk*; (b) para maior sensibilidade, os pares de eletrodos devem ser posicionados ao longo das fibras musculares; (c) para a fixação, são preferíveis áreas que não obstruam a movimentação e visão do paciente/voluntário e que possuam boa referência anatômica (fácil localização), o



que facilita a fixação dos eletrodos durante os experimentos realizados. A Figura 11 apresenta os diferentes posicionamentos dos eletrodos sobre a musculatura e seu respectivo efeito no sinal de saída em relação a amplitude e densidade espectral. Pela Figura 11, é possível perceber que o posicionamento ventral do eletrodo privilegia o sinal em termos de valores de amplitude e frequência, oferecendo um sinal mais descritivo.



**Figura 11** Influência do posicionamento de eletrodos no sEMG (adaptado livremente de DE LUCA, 1997).

### 2.2.2.2 Musculatura do braço

Considerando a variedade de músculos na região de interesse e os movimentos a serem classificados, é pertinente realizar uma análise anatômica da região corporal de interesse. Para trabalhos envolvendo sEMG e membros superiores é considerada a musculatura da mão, do antebraço e braço. Portanto, convém mostrar a musculatura da região, os músculos e a sua relação com os movimentos de interesse.

A Figura 12 mostra a musculatura do braço e antebraço humano em vista anterior superficial e vista anterior profunda enquanto a Tabela 1 apresenta a relação entre alguns músculos e alguns movimentos comumente executados.


**Tabela 1 Principais músculos superficiais do braço e antebraço e suas funções.**

<b>MÚSCULO</b>	<b>MOVIMENTO</b>
Bíceps braquial	Flexão da mão e supinação do antebraço; flexão do braço.
Braquial	Flexão do antebraço.
Braquiorradial	Flexão do antebraço.
Tríceps braquial	Extensão do antebraço/ braço.
Flexor radial do carpo	Flexão/abdução da mão.
Flexor ulnar do carpo	Flexão/abdução da mão.
Palmar longo	Flexão da mão.
Flexor superficial dos dedos	Flexão das falanges médias de cada dedo.
Extensor radial do carpo	Extensão/abdução a mão.
Extensor ulnar do carpo	Extensão/abdução a mão.
Extensor dos dedos	Extensão das falanges.

Fonte: Adaptado livremente de TORTORA, 2007.

O capítulo 2 deste trabalho apresenta uma sucinta revisão sobre a fisiologia e os sinais mioelétricos envolvidos neste trabalho. Para informações mais aprofundadas sobre os temas é recomendada a leitura dos seguintes livros:

- BELTRAMINI, L.M. **Elementos de histologia e anátomo-fisiologia humana**. São Carlos: USP, 1997.
- BRONZINO, J. & ENDERLE, J. **Introduction to Biomedical Engineering** 3<sup>rd</sup> Edition, Burlington, MA, EUA, 2012, Elsevier Inc. (Capítulos 3 e 4);
- GUYTON, A.C. **Fisiologia Humana**. Rio de Janeiro: Guanabara Koogan, 2006 (Unidade II);
- MOORE, J. & ZOURIDAKIS, G., **Biomedical Technology and Devices Handbook**, Boca Raton, FL, EUA, 2004 CRC Press LLC (Capítulo 4);
- TORTORA, G. J. **Corpo humano: fundamentos de anatomia e fisiologia**, 10 ed. Guanabara Koogan, Rio de Janeiro, 2007 (Capítulo 8).



**Figura 12 Principais músculos superficiais do braço e antebraço sEMG (TORTORA, 2007).**

### 3 REGRESSÃO LOGÍSTICA

Regressão logística (também chamada de classificador de máxima entropia) é um modelo de classificação probabilística. A Regressão Logística (RL) é usada tipicamente para prever as probabilidades de uma instância de teste pertencer a uma categoria com base nos valores das variáveis preditoras (LAVALEY, 2008). Segundo (LEE & LIU, 2003), uma das principais vantagens do uso do modelo de RL está em sua clareza e simplicidade, que é amplamente utilizado em áreas como ciências médicas e sociais.

O modelo de Regressão Logística se assemelha ao de regressão linear, entretanto, apesar do nome, a RL é denominada como um classificador ao invés de um regressor (BISHOP, 2006), apresentando em sua saída, uma variável discreta. Em seu modelo mais comum, a RL se apresenta como um modelo de saída binária. Neste modelo, a variável de resposta  $Y$  pode assumir valores discretos, como por exemplo,  $Y=0$  e  $Y=1$  denominados respectivamente de "fracasso" e "sucesso". Por exemplo, neste caso, "sucesso" é o evento de interesse a ser classificado. Apesar de ser mais comumente utilizado em sua forma binomial, o modelo de Regressão Logística também possui extensões para trabalhar com diversas classes de saída. Esta abordagem é chamada de Regressão Logística Multinomial (RLM). Neste trabalho foi desenvolvido o modelo de RL Binomial (RLB) onde cada saída corresponde à probabilidade do movimento pertencer a uma das 17 classes que representam os movimentos a serem classificados.

Para efetuar a classificação de certa instância, o modelo de RL se utiliza de variáveis independentes que acompanham cada entrada - com exceção da primeira - e promovem a adequação (regressão) - em inglês, *fitting* - do modelo ao problema proposto. Ao conjunto de variáveis e entradas que descreve a relevância de cada fator na predição, dá-se o nome de função preditora.

### 3.1 FUNÇÃO PREDITORA

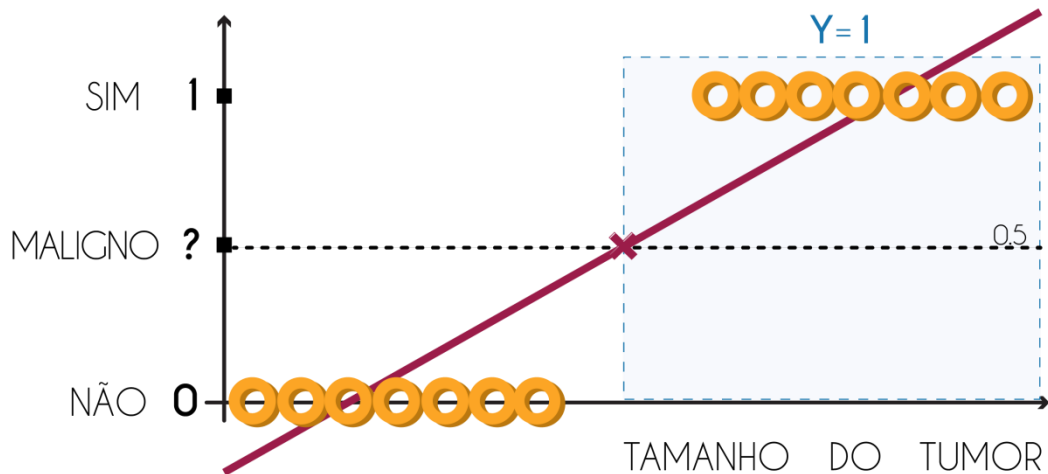
A Função Preditora (FP) consiste em um vetor  $\beta_n$  de  $n+1$  coeficientes que busca adequar o modelo desenvolvido aos dados de entrada. Desta forma, o desempenho do classificador depende intrinsecamente de quão bem ajustados se encontram estes parâmetros. A FP é encontrada em diversos métodos de classificação estatística como *Support Vector Machines* (SVM), Redes Neurais Artificiais (RNA), entre outras (NG, 2014). Como a FP objetiva atribuir um nível de influência a cada entrada do modelo, é natural que o vetor que a representa seja de igual tamanho ao das entradas mais um (tendo em vista de que o termo  $\beta_0$  independe dos valores de entrada). A equação genérica da FP é mostrada em (1).

$$FP = \beta_0^{(i)} + \beta_1^{(i)} x_1^{(i)} + \beta_2^{(i)} x_2^{(i)} + \dots + \beta_n^{(i)} x_n^{(i)} \quad (1)$$

Onde:  $\beta$  simboliza um vetor com fatores da equação preditora a ser ajustado na etapa de treino e  $\beta_0 = 1$  (valor de *offset* do modelo);  $x_n$  representa um vetor de entrada - características extraídas do sinal - para o classificador;  $i$  representa a iteração do algoritmo de otimização para o ajuste do modelo e  $n$  o número total de entradas.

Desta forma, se atinge a distribuição ponderada da influência de cada entrada na probabilidade de certa instância de teste pertencer a uma classe (MITCHELL, 1997). Entretanto, o modelo descrito pela Equação (1) é linear, o que não é adequado para um problema de classificação.

A Figura 13 demonstra a classificação realizada por um modelo linear para duas classes. Neste exemplo é desejada a classificação de um diagnóstico - maligno ou benigno - de câncer, em função do tamanho do tumor, que consiste na variável de entrada do classificador. Neste exemplo o limiar de decisão consegue separar com sucesso as duas classes propostas para a saída, acomodando adequadamente cada entrada em sua devida classe.




**Figura 13** Modelo de regressão linear utilizado como classificador onde a área em azul corresponde à saída positiva ( $Y=1$ ). (Adaptado livremente de NG, 2014).

A classificação obtida parece adequada quando os dados de entrada se mantêm dentro de uma faixa prevista; no entanto, na Figura 14 fica evidenciada a falta de robustez deste método como um classificador eficiente para sinais estocásticos ao inserir uma anormalidade como variável de entrada (NG, 2014). A nova entrada provoca uma variação tal no limiar de entrada que o impede de separar adequadamente todas as entradas, dessa forma, ocorre o erro de classificação para parte dos dados destinados a classe positiva ( $Y=1$ ).

Outro problema ocasionado pela regressão linear é o valor resultante do modelo, que para casos extremos tende à  $-\infty$  ou  $+\infty$ , o que não é interessante considerando que se deseja trabalhar com distribuição de probabilidades da ocorrência de um evento. Há ainda outra razão que inviabiliza o uso da regressão linear neste tipo de problema: a regressão linear pressupõe um relacionamento linear entre as variáveis de entrada. Em sistemas com variável de saída dicotômica, esta condição é frequentemente violada (FIELD, 2009).

Para evitar estes tipos de problemas é utilizada a Regressão Logística. A RL aparece como subterfúgio para representar (adequar) os dados não lineares de entrada através de um modelo logarítmico (função logística, ou *logit*). Desta forma é possível criar um modelo de predição que se adequa aos dados acomodando a probabilidade de ocorrência entre 0 e 1,

sendo os valores próximos a 0 de baixa probabilidade de ocorrência e os próximos a 1, com probabilidade alta de ocorrer (BISHOP, 2006; EL-KOKA *et al.*, 2013; NG, 2014).



**Figura 14** Erro de classificação causado em função da nova entrada, parte dos dados é erroneamente classificada como “falsa” ( $Y=0$ ). (Adaptado livremente de NG, 2014).

### 3.2 DISTRIBUIÇÃO DE PROBABILIDADES

Cada saída de movimento prevista para o modelo é descrita pela distribuição de probabilidades binomial. A distribuição binomial fornece a probabilidade de  $m$  ocorrências  $Y=1$  para  $i$  amostras independentes da variável de entrada, quando a probabilidade ( $p$ ) de  $Y=1$   $\in [0, 1]$ . Genericamente, a distribuição binomial é representada pela Equação (2):

$$\text{Bin}(i|m, p) = \binom{m}{i} p^i (1-p)^{m-i} \quad (2)$$

A Equação (2) aglutina as expressões utilizadas para descrever a probabilidade de “sucesso”  $P(Y=1) = p$  e seu complemento, a “falha”  $P(Y=0) = (1-p)$ . As probabilidades de ocorrência dos sucessos, que no caso deste trabalho identificam os movimentos de interesse, são dependentes das variáveis de entrada, como descrito na FP (Equação (1)). Entretanto para a utilização no modelo de RL, a FP é inserida na função logística,  $g(\beta^T x) = h_\beta(x)$ , descrita pela Equação (3).

$$P(y = 1|x; \beta) = h_\beta(x) = \frac{1}{1+e^{-\beta^T x}} \quad (3)$$

Desta forma, para o problema proposto, por (3) é possível calcular a probabilidade de uma instância de entrada  $x$ , parametrizada pelos coeficientes do modelo  $\beta$  a ser classificada como a classe de interesse ( $Y=1$ ). (BISHOP, 2006), enfatiza a utilidade da função logística pelo fato dela poder transformar uma entrada qualquer em uma saída confinada entre 0 e 1, o que pode ser diretamente interpretável como uma probabilidade de ocorrência de um evento de interesse. A Figura 15 representa a distribuição de probabilidades da função logística e sua curva característica. Nela é fácil perceber que para valores extremos de entradas, a saída tende respectivamente para 0 e 1 ao invés de  $-\infty$  ou  $+\infty$ , como no caso da regressão linear. Este intervalo de resposta é particularmente útil em situações como a que ocorre no exemplo da classificação do câncer em função do tamanho do tumor exposta nas Figuras 13 e 14, que possuem saída dicotômica (NG, 2014).




Figura 15 Função logística.

### 3.3 ADEQUAÇÃO DOS PARÂMETROS DO MODELO

Como regra geral, o desempenho do algoritmo de classificação deve ser tão bom quanto a adequação dos coeficientes do modelo às entradas fornecidas no processo de treinamento (é importante salientar também os parâmetros  $\alpha$  e  $\lambda$ , que se mostram bastante críticos no processo de adequação do modelo). Na prática a obtenção dos parâmetros  $\beta$  do modelo consiste em um processo iterativo ao fim do qual, se obtém os melhores valores possíveis para a adequação dos coeficientes  $\beta$  às entradas  $x$  (BISHOP, 2006; NG, 2014).



Especificamente, a estimação destes parâmetros deve obedecer ao critério da máxima verossimilhança, onde são selecionados os coeficientes que tornam os valores observados mais prováveis de terem ocorrido. Desta forma são gerados modelos mais representativos em função das entradas utilizadas para a sua adequação (LEE & LIU, 2003; MITCHELL, 1997).

### 3.3.1 Limiar de decisão

Os coeficientes definidos estabelecem o limiar de decisão do classificador, que serve para arbitrar quando uma entrada é classificada como 0 ou 1. Para a curva descrita pela função logística na Figura 14 é possível perceber que o limiar de decisão que separa as duas classes a serem classificadas é dado pela Equação (4) para  $Y=1$  e pela Equação (5) para  $Y=0$ . Onde  $g$  representa a função logística,  $\beta$  os coeficientes do modelo e  $x$  as respectivas entradas.

$$Y=1, \forall g(\beta^T x) \geq 0,5 \quad (4)$$

$$Y=0, \forall g(\beta^T x) < 0,5 \quad (5)$$

### 3.3.2 Limiar de decisão linear

Os limiares de decisão podem ou não ser lineares dependendo das entradas a serem classificadas (NG, 2014). Um exemplo de dados de entrada para os quais um limiar de decisão linear é adequado é representado na Figura 16 através de duas classes: cruces ( $Y=1$ ) e círculos ( $Y=0$ ).

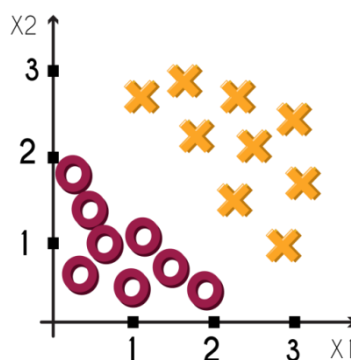


Figura 16 Dados de exemplo para definição de limiar de decisão linear.

Devido ao modelo composto por duas entradas, o limiar de decisão pode ser descrito pela Equação (6).

$$h_{\beta}(x) = g(\beta_0 + \beta_1 x_1 + \beta_2 x_2) \quad (6)$$

Sendo  $h_{\beta}(x)$  o cálculo da hipótese em função de  $\beta_n$  que representa os coeficientes lineares calculados para as entradas  $x$  em uma instância  $n$ .

Supondo os valores para o vetor de coeficientes  $\beta$  descritos na Equação (7):


$$\beta = \begin{bmatrix} -3 \\ 1 \\ 1 \end{bmatrix} \quad (7)$$

A Equação (8) descreve o limiar de decisão em função dos valores de  $x$ :

$$g(\beta^T x) = -3 + x_1 + x_2 \geq 0 \quad (8)$$

$$x_1 + x_2 \geq 3 \quad (9)$$

Conseqüentemente, o limiar de decisão pode ser definido pela reta azul na Figura 17.

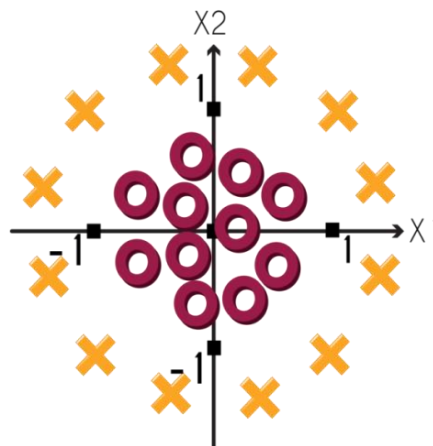


**Figura 17 Limiar de decisão linear.**

Entretanto, geralmente os dados de entrada – principalmente em sistemas estocásticos – não possuem uma distribuição linear e tão bem definida. Existe a probabilidade de os dados exigirem um limiar de decisão não linear para a sua devida classificação (NG, 2014).

### 3.3.3 Limiar de decisão não linear

Outros modos de gerar o limiar de decisão surgem quando não há a conformidade em um modelo linear. Deve-se gerar então um modelo não linear para realizar a classificação. Um exemplo desse tipo de limiar pode ser observado na Figura 18. Tendo o seu modelo descrito na Equação (10) e os valores dos coeficientes  $\beta$  na Equação (11).



**Figura 18** Dados de exemplo para definição de limiar de decisão não linear.

$$h_{\beta}(x) = g(\beta_0 + \beta_1 x_1^2 + \beta_2 x_2^2) \quad (10)$$

$$\beta = \begin{bmatrix} -1 \\ 1 \\ 1 \end{bmatrix} \quad (11)$$

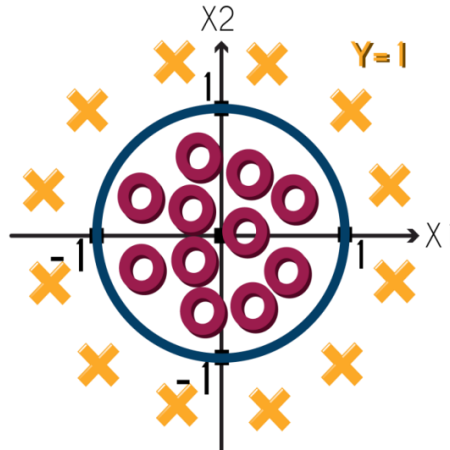
Onde  $h_{\beta}(x)$  representa a hipótese em função dos coeficientes  $\beta_n$  calculados para as entradas  $x$  em uma instância arbitrária, descrevendo a função logística  $g$  (NG, 2014). Através do modelo e valores dos coeficientes definidos, pode-se chegar ao valor das variáveis para o limiar de decisão, descritos nas Equações (12) e (13).

$$g(\beta^T x) = -1 + x_1^2 + x_2^2 \geq 0 \quad (12)$$

$$x_1^2 + x_2^2 \geq 1 \quad (13)$$

A Figura 19 apresenta o limiar de decisão calculado. As ordens e equações dos limiares de decisão podem ser radicalmente diferentes de acordo com as entradas do modelo. Para obter um modelo robusto e valores adequados dos coeficientes, geralmente é utilizado

um algoritmo de otimização matemática que minimiza a função custo do modelo, diminuindo assim o erro de predição e aproximando as saídas encontradas (preditas) de seus valores reais (NG, 2014).



**Figura 19 Limiar de decisão não linear calculado.**

### 3.4 FUNÇÃO CUSTO

Em termos práticos, a função custo pode ser definida como a diferença entre a hipótese predita através dos valores momentâneos dos parâmetros do modelo e a saída real do sistema. A Equação (14) apresenta a função custo geralmente aplicada a funções convexas para a minimização da função que representa o erro quadrático médio obtido enquanto a Equação (15) descreve a função custo genericamente.

$$\text{Custo}(h_{\beta}(x^{(i)}), Y^{(i)}) = \frac{1}{2}(h_{\beta}(x^{(i)}) - Y^{(i)})^2 \quad (14)$$

$$J(\beta) = \frac{1}{m} \sum_{i=1}^m \text{Custo}(h_{\beta}(x^{(i)}), Y^{(i)}) \quad (15)$$

Onde:  $h_{\beta}(x)$  corresponde à probabilidades de saída predita pelos valores momentâneos do modelo para uma instância  $i$  das variáveis de entrada;  $Y$  corresponde valor real da probabilidade de saída binomial (1 ou 0);  $\text{Custo}$  corresponde ao erro quadrático do valor calculado para  $i$ -ésima instância;  $m$  corresponde ao total de movimentos (classes) a serem

treinados e  $J(\beta)$  representa o modelo utilizado para calcular a função custo em funções convexas (NG, 2014).

No modelo de regressão logística não é aconselhável a utilização direta da Equação (15) para a minimização do custo em função da Equação (3). A sigmoide que descreve o modelo logístico é não-linear e gera uma função custo não estritamente convexa, com diversos mínimos locais. Por isto deve-se adaptar o cálculo do custo em função do modelo logístico. Para tanto é utilizado o cálculo logarítmico da função custo, conforme apresentado na Equação (16). Através desta adaptação gera-se uma função estritamente convexa que facilita o processo de obtenção do mínimo global da função e conseqüentemente os valores dos coeficientes que proporcionam o menor erro entre a hipótese e a saída real da respectiva entrada (NG, 2014).

$$Custo(h_{\beta}(x^{(i)}), Y^{(i)}) = \begin{cases} -\log(h_{\beta}(x^{(i)})), & \text{para } Y = 1 \\ -\log(1 - h_{\beta}(x^{(i)})), & \text{para } Y = 0 \end{cases} \quad (16)$$

Onde:  $-\log(h_{\beta}(x))$  descreve a probabilidade da entrada  $x$  ser classificada como “sucesso” e  $-\log(1 - h_{\beta}(x))$  (que é a probabilidade complementar), descreve a probabilidade da entrada ser classificada como “falha”, ambas em uma  $i$ -ésima instância.

Considerando estes dois cenários e considerando  $Y^{(i)}$  a probabilidade de saída para “sucesso” (1),  $(1 - Y^{(i)})$  para a probabilidade de saída “falha” (0) e esses dois os únicos valores possíveis para  $Y$ , é possível reescrever a função custo conforme os cenários expostos na Equação (17). Onde  $Y^{(i)}\log(h_{\beta}(x^{(i)}))$  representa a parcela da equação relativa ao “sucesso” e  $(1 - Y^{(i)})\log(1 - h_{\beta}(x^{(i)}))$  relativa a “falha” (NG, 2014; MITCHELL, 2007). Desta forma, é calculada a saída para estes dois casos distintos (apresentadas nas Equações (17), (18), (19), (20) e (21)). Através dos cálculos apresentados, é possível reescrever a função custo de forma mais compacta e equivalente, como apresentado na Equação (22).

Se  $Y=1$ :

$$Custo(h_{\beta}(x^{(i)}), Y^{(i)}) = Y^{(i)} \log h_{\beta}(x^{(i)}) + (1 - Y^{(i)}) \log (1 - h_{\beta}(x^{(i)})) \quad (17)$$

$$Custo(h_{\beta}(x^{(i)}), Y^{(i)}) = (1) \log h_{\beta}(x^{(i)}) + (1 - (1)) \log (1 - h_{\beta}(x^{(i)})) \quad (18)$$

$$Custo(h_{\beta}(x^{(i)}), Y^{(i)}) = \log h_{\beta}(x^{(i)}) \quad (19)$$

Se  $Y=0$ :

$$Custo(h_{\beta}(x^{(i)}), Y^{(i)}) = (0) \log h_{\beta}(x^{(i)}) + (1 - (0)) \log (1 - h_{\beta}(x^{(i)})) \quad (20)$$

$$Custo(h_{\beta}(x^{(i)}), Y^{(i)}) = \log (1 - h_{\beta}(x^{(i)})) \quad (21)$$

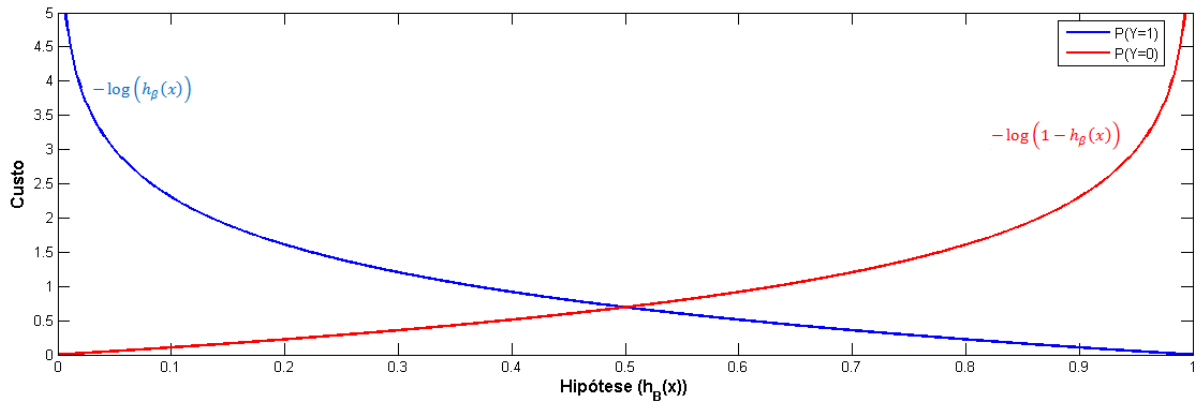
Juntando a Equação (19) e a equação (21), considerando  $Y$  como variável de entrada, é possível expressar a função custo pela Equação (22).

$$J(\beta) = -\frac{1}{m} \sum_{i=1}^m \left[ Y^{(i)} \log h_{\beta}(x^{(i)}) + (1 - Y^{(i)}) \log (1 - h_{\beta}(x^{(i)})) \right] \quad (22)$$

Na Figura 20 é possível observar as curvas características que descrevem o custo em função da probabilidade da hipótese descrita na Equação (16), juntando os dois termos da equação é possível formar a função custo estritamente convexa utilizada no processo de otimização para a obtenção do mínimo global. É possível observar que para a classe falha ( $Y=0$ ) em vermelho, quando a saída predita também é zero, o algoritmo tem  $Custo = 0$ , ou seja, não é penalizado. Já na situação oposta, quando o algoritmo prediz uma probabilidade zero enquanto deveria predizer um, é penalizado por um fator tendendo ao infinito (possui um alto custo). Complementarmente, o mesmo acontece para a classe de sucesso ( $Y=1$ ) em azul, para predições positivas (NG, 2014).

Uma vez que se tem a resposta da função custo sendo representada por uma função estritamente convexa, o próximo passo consiste na minimização dessa função em termos dos coeficientes  $\beta$  (MOFARREH-BONAB & GHORASHI, 2013), o que consiste em achar os

coeficientes do modelo logístico descrito pela Equação (3). Para a minimização desta função foi utilizado o método de descida do gradiente, detalhado no Subcapítulo 3.4.1.



**Figura 20** Custo em função da saída prevista para os casos de sucesso ( $y=1$ ) em azul e falha ( $y=0$ ), em vermelho.

### 3.4.1 Método de descida do gradiente

O método de descida do gradiente (*gradient descent method*) é uma das técnicas mais antigas e mais amplamente utilizadas para minimizar uma função definida em espaço de entrada multidimensional. Apesar da sua convergência lenta, o método é frequentemente utilizado em técnicas de otimização envolvendo funções convexas devido à sua simplicidade e a garantia de convergência ao menos a um mínimo local (DU, 2014; MOFARREH-BONAB & GHORASHI, 2013). O método de descida do gradiente tem sido utilizado em diversas aplicações como: (a) na regressão linear para minimizar o erro da função alvo; (b) em redes neurais para convergência dos coeficientes de peso da rede (MITCHELL, 2007); (c) na aprendizagem de máquina por reforço; (d) na percepção de objetos 3D, entre outras aplicações (LIU, 2014).

O processo de otimização matemática que compõe a minimização da função custo consiste em derivar a função em relação aos parâmetros do vetor  $\beta$  e dessa forma atingir o valor de mínimo, de forma a construir um modelo adequado às entradas utilizadas nesta etapa (MOFARREH-BONAB & GHORASHI, 2013; MITCHELL, 2007). O gradiente de uma

função indica a máxima taxa de variação no espaço de parâmetros  $\beta$ , quando usado em uma função estritamente convexa e em sentido negativo, tende a conduzir para o mínimo global desta função. A escolha do “tamanho do passo” (módulo de  $\alpha$ ) do gradiente é um fator importante para assegurar a convergência do método, pois uma vez que tiver um valor muito elevado provocará um “rebatimento” em torno do mínimo global, impedindo a convergência e quando for muito pequeno, acarretará em tempo muito grande para a convergência (NG, 2014; MITCHELL, 2007). Considerando a variável  $\alpha$  como uma variável balizadora para controlar o tamanho do passo do gradiente,  $\beta_k$  como os correntes valores dos coeficientes na  $k$ -ésima iteração e  $\beta_{k+1}$  como valores futuros ( $(k+1)$ -ésima iteração), é possível apresentar o cálculo do gradiente na Equação (23), considerando as derivadas parciais em relação a cada coeficiente  $\beta$ .

$$\beta_{k+1} = \beta_k - \alpha_k \left[ \frac{\partial}{\partial \beta_k} J(\beta_k) \right] \quad (23)$$

Resolvendo a derivada na Equação (23) tem-se então o cálculo de cada coeficiente  $\beta$  da função custo considerando cada entrada  $x^{(i)}$  para cada  $k$  iteração do modelo. A Equação (24) apresenta o método de obtenção dos coeficientes  $\beta$  do modelo, onde o gradiente da função custo,  $\nabla(J(\beta_k^{(i)}))$ , é explicitado em função da diferença da saída predita  $h_{\beta(x)}^{(i)}$  e da saída real  $Y^{(i)}$  (NG, 2014; MITCHELL, 2007).

$$\beta_{k+1}^{(i)} = \beta_k^{(i)} - \alpha \left[ \frac{1}{m} \sum_{i=1}^m \nabla \left( J(\beta_k^{(i)}) \right) \right] x_k^{(i)} \quad (24)$$

### 3.4.2 Regularização

Uma vez obtidos os coeficientes do modelo através do processo de otimização matemática os modelos para cada classe são definidos e teoricamente adequados para o processo de classificação. No entanto, por vezes, o conjunto de dados utilizado para a formação dos modelos ou o próprio processo de otimização matemática (quando não



consegue atingir um valor adequado para os coeficientes) não são capazes de gerar o melhor modelo para a classificação. Duas situações opostas derivam deste problema e são denominadas *underfitting* (falta de adequação do modelo aos dados) e *overfitting* (excesso de adequação do modelo aos dados e incapacidade de reconhecer pequenas variações). Em uma situação ideal, o classificador deve estar em meio a estas duas situações, pois deve ser capaz de se adequar aos dados, mas não realizar isto em demasia, para que não identifique erroneamente uma entrada como pertencente a uma determinada classe (DU, 2014). Outra situação decorrente é que uma determinada entrada pode influenciar demasiadamente a escolha dos coeficientes, para evitar estes problemas é utilizado um termo  $\lambda$  adicional na função custo descrita na Equação (24) em um processo chamado regularização. Desta forma a nova função custo regularizada a ser minimizada no processo de otimização matemática é apresentada na Equação (25).

$$\beta_{k+1}^{(i)} = \beta_k^{(i)} - \alpha \left[ \frac{1}{m} \sum_{i=1}^m \nabla \left( J(\beta_k^{(i)}) \right) x_k^{(i)} + \frac{\lambda}{m} \beta_k \right] \quad (25)$$

Sendo  $\beta_{k+1}$  o valor futuro a ser calculado para a  $k$ -ésima iteração ( $\beta_k$ ) com a variável  $\alpha$  controlando o tamanho do passo da iteração, dado pela diferença entre o valor predito ( $h_{\beta(x)}^{(i)}$ ) e a saída real ( $Y^{(i)}$ ), representado pelo gradiente da função custo  $\nabla \left( J(\beta_k^{(i)}) \right)$  para uma instância  $i$  de movimento (NG, 2014, BISHOP, 2006). Adicionalmente, um termo não negativo responsável pela regularização matemática é introduzido à função custo utilizada na regressão logística. Geralmente este parâmetro de regularização é pré-definido empiricamente pelo desenvolvedor do código. (EL-KOKA *et al.*, 2013) descrevem um método recomendando a obtenção do parâmetro regularizador através de testes para verificar a maior taxa de acerto em função da variação deste parâmetro. Este trabalho seguiu esta metodologia, que também foi estendida para a obtenção de  $\alpha$ , este procedimento é detalhado no Subcapítulo 4.4.2.1.

O Subcapítulo 3.3.4 deste trabalho trata da abordagem da regularização e da adequação do modelo (*goodness of the fit*) de forma sucinta, o tópico possui muitas derivações e abordagens distintas. Como indicação para o aprofundamento do tópico o autor deixa indicados os seguintes livros/artigos:

- DU, K.-L. & SWAMY, M. N. S. **Neural Networks and Statistical Learning**, DOI: 10.1007/978-1-4471-5571-3\_2, © Springer-Verlag, Londres 2014 (Capítulos 4 e 6);
- LEE W. S. & LIU, B. **Learning with Positive and Unlabeled Examples Using Weighted Logistic Regression** Proceedings of the Twentieth International Conference on Machine Learning (ICML-2003), Washington DC, 2003;
- BISHOP, CHRISTOPHER M.. **Pattern Recognition and Machine Learning**. Springer, 2006 (Capítulo 5);
- LAVALLEY, MICHAEL P. **Logistic Regression** Department of Biostatistics, Boston University School of Public Health, 2008;
- GRÉGOIRE, G. **Logistic Regression - Regression Methods for Astrophysics** EAS Publications Series, 66 (2014) 89–120.
- EL-KOKA, A., ERA K., & KANG, D. **Regularization Parameter Tuning Optimization Approach in Logistic Regression** International Conference on Advanced Communication Technology (ICACT), Pyeong Chang, South Korea, 2013.

### 3.5 MÉTODO ONE-VERSUS-ALL (OVA)

O *One-Versus-All* (um contra todos) ou *One-Versus-Rest* (um contra o resto) é uma abordagem frequentemente utilizada quando se deseja decompor um problema multinomial em um problema binomial multiclass (LORENA *et al.*, 2009). Esta abordagem é utilizada pelo fato da decomposição binária apresentar melhor desempenho quando comparada a abordagens multiclass convencionais (LORENA *et al.*, 2009; CHI, 2015). Como exemplo, a Figura 21 mostra a aplicação da técnica para a classificação em três classes distintas.

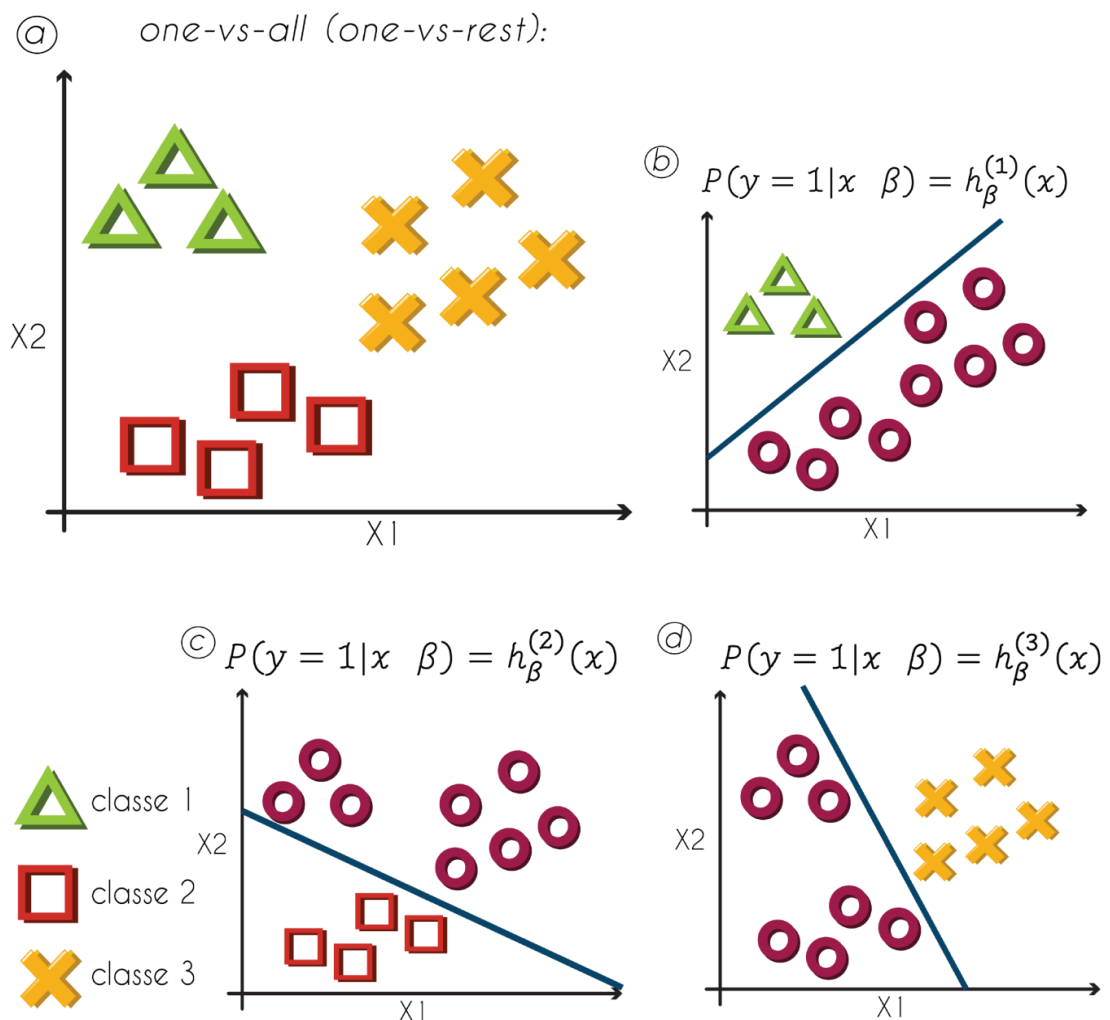


Figura 21 Exemplo de aplicação do OVA para a separação de dados em três classes distintas, para cada classe apresentada em (a) há a geração de um modelo: (b) representa a classe 1 (triângulos); (c) representa a classe 2 (quadrados) e (d) a classe 3 (x). Em cada modelo é calculada a probabilidade do dado pertencer àquele modelo contra a probabilidade de pertencer a qualquer outro. (Adaptado livremente de NG, 2014).

Nas aplicações do OVA o número de amostras de cada classe de interesse é proporcionalmente pequeno quando comparado ao total de amostras de todas as classes. Neste trabalho foi utilizado o OVA de maneira que cada uma das classes representa um dos movimentos a ser classificado e em cada modelo é calculada a probabilidade de um dado pertencer a determinada classe ou a qualquer uma das outras.

### **3.6 TRABALHOS RELACIONADOS À CLASSIFICAÇÃO DE MOVIMENTOS ATRAVÉS DE PROCESSAMENTO DE SINAIS DE SEMG**

Trabalhos relacionados à caracterização de movimentos através do processamento de sinais de sEMG geralmente têm por objetivo fornecer uma interface de controle mais natural, intuitiva e confortável ao usuário. Esse controle tradicionalmente é realizado com sinais provenientes da musculatura remanescente presente no grupo muscular do amputado usuário do sistema. Atualmente alguns grupos de pesquisa tem investido em pesquisas focando a completa substituição do membro natural com um braço eletromecânico controlado por musculatura adjacente àquela substituída pela prótese. Como apresentado por (OSBORN *et al.*, 2013), outra abordagem mais moderna consiste em fornecer *feedbacks* ao usuário como sensores de força ou de deslizamento no caso de próteses de mão.

Um dos fatores que ainda impede o uso em grande escala de próteses comerciais é que uma prótese mais natural deve ser capaz de lidar com diversos graus de liberdade simultâneos utilizados no dia a dia, o que ainda representa um grande desafio para as técnicas atuais. Tipicamente a inabilidade de medir perfeitamente ativações musculares está em parte relacionada com alguns fatores como profundidade e espessura da musculatura de interesse, zonas de inervação, qualidade do contato do eletrodo com a pele, impedância da pele, intensidade da contração muscular, *cross-talk*, entre outros fatores. Quando são realizadas medições em diversos músculos com o intuito de se extrair em medidas de sinergias entre os

músculos esses fatores são ampliados e arranjos de controle multifuncional simultâneo devem lidar com estes e outros fatores como cancelamento de amplitude, posicionamento de eletrodos e número e seleção de músculos (ISON *et al.*, 2014).

Outro fator é desenvolver um dispositivo prático que permita portabilidade e usabilidade natural ao usuário. Neste sentido, entra-se no mérito da relação de canais. Para que a prótese seja a mais antropomórfica possível, a mesma deve realizar um grande número de movimentos, e quanto maior for o número de movimentos, maior deve ser o número de eletrodos e mais eficiente o reconhecimento dos padrões dos sinais eletromiográficos (FAVIEIRO, 2012).

Independentemente do tipo de abordagem e classificador utilizados, a extração de características é uma parte vital no processo de classificação do movimento. Afinal, pelas características é que são construídos os modelos dos classificadores. Uma extração de características ideal converte um pacote de sinais de sEMG em descritores repetitivos e descritivos e a escolha das características convenientes é frequentemente mais importante do que o esquema de controle escolhido com relação ao bom desempenho de controle multifuncional (ENGLEHART, 1999). Basicamente existem dois domínios para a extração de características: tempo e frequência. (HUDGINS *et al.*, 1993) estabeleceram as bases do primeiro sistema de controle utilizando um conjunto de características no domínio do tempo. Desde então diversas técnicas de extração foram propostas para complementar o trabalho iniciado por (HUDGINS *et al.*, 1993), o que inclui características extraídas no domínio da frequência e técnicas híbridas no domínio tempo-frequência (ISON *et al.*, 2014). Algumas destas técnicas e características são apresentadas na Tabela 2.

Em relação às abordagens de Inteligência Computacional (IC), existem diversas técnicas utilizadas para a detecção e reconhecimento dos sinais de sEMG entre elas Redes Neurais Artificiais (RNA), *Fuzzy Logic* (FL), Algoritmos Genéticos (AG), *Support Vector*

*Machines* (SVM), Redes Bayesianas (RB), *Linear Discriminant Analysis* (LDA), *Independent Component Analysis* (ICA), *Principal Component Analysis* (PCA) e Regressão Logística (RL).

RNA é um dos métodos de classificação mais clássicos e utilizados em *Machine Learning*. Por exemplo, em sua pesquisa, (AHSAN *et al.*, 2011) apresentam a detecção de quatro movimentos de mão (para cima, para baixo, direita e esquerda) através da utilização de sete características extraídas dos domínios tempo e tempo-frequência: valor médio absoluto, RMS, variância, desvio padrão, cruzamento por zero, *slope sign change* e amplitude de Willison. Já (CENE *et al.*, 2015) propõem o uso de uma RNA adaptativa para mitigar sinais que interferem na extração de características precedente ao treino da RNA, realizando um treino somente com canais que contribuem significativamente para o processo de classificação.

**Tabela 2 Características extraídas para o uso na classificação e caracterização de movimentos.**

DOMÍNIO	CARACTERÍSTICAS	VANTAGENS	DESVANTAGENS
<b>Tempo</b>	Envelope Linear, Valor Médio Absoluto, RMS, Cruzamentos por Zero, <i>Slope Sign Change</i> , Comprimento da Forma de Onda, Complexidade da Onda, Amplitude de Willison, Histograma	Simplicidade computacional, Relação direta com a força e amplitude da contração muscular	Sensibilidade ao ruído, Mudanças transientes do sEMG, Cancelamento de amplitude
<b>Frequência</b>	Momentos Espectrais de Potência, Densidade Espectral, Medias da Magnitude Espectral, Frequência Mediana,	Detecção de fadiga	Complexidade computacional, Baixa resolução temporal, Vazamento espectral, Elevada variância
<b>Tempo- Frequência</b>	Transformada Wavelet, Transformada Wavelet Discreta, STFT ( <i>short-time Fourier transform</i> ), STTT ( <i>short-time Thompson transform</i> )	Resolução em tempo e frequência, Representação transiente e estática, Distinção de sinais não-estacionários	Características abstratas, Saídas com alta dimensionalidade, Muitos parâmetros de controle

Fonte: Adaptado livremente de ISON *et al.*, 2014.

No que concerne a aplicação de lógica *Fuzzy*, (BALBINOT & FAVIEIRO, 2013; FAVIEIRO, 2012) apresentam métodos baseados em *Neuro-Fuzzy* para utilização de controle mioelétrico. Já (GUVENC *et al.*, 2014) apresentam a implementação de um controlador hierárquico *Neuro-Fuzzy* que se adapta satisfatoriamente a pessoas que geram atividades musculares diferenciadas.

SVM consiste em uma técnica usada para classificar dados em dois grupos através da construção de um hiperplano de separação (limiar de decisão) que visa maximizar as distâncias entre os grupos e o hiperplano. Apesar de existirem vários hiperplanos capazes de separar os pontos de classes distintas em um espaço de alta dimensão, apenas um dos hiperplanos será ótimo (NILSON & BALBINOT, 2014). A capacidade de generalização é grande se o hiperplano puder ser construído por um número pequeno de vetores de suporte (HAYKIN, 2001). (NILSON & BALBINOT, 2014) apresentam a utilização desta técnica para a classificação de nove movimentos do segmento mão-braço.

Como apresentado em (HAN & JO, 20014; BU *et al.*, 2009), recentemente houveram algumas abordagens em torno de métodos bayesianos para a utilização de controle mioelétrico. Modelos Ocultos de Markov (HMM) (CHIANG *et al.*, 2008) e Modelos de Mistura de Gaussianas (GMM) (HUANG & ENGLEHART, 2005; QICHUAN *et al.*, 2015) foram utilizados para realizar a classificação de movimentos em múltiplos membros usando sinais mioelétricos. Segundo (HAN & JO, 2014) os modelos bayesianos são geralmente assertivos quando se deseja atingir um modelo adaptativo sem informações concretas a respeito dos parâmetros do modelo.

Devido à sua natureza, os métodos baseados em LDA, ICA e PCA aparecem como alternativas interessantes quando o objetivo do trabalho é isolar alguns canais de forma a selecionar os mais eficientes para a caracterização do sinal.

O método do PCA trata muito bem a abordagem focada em sinergia dos músculos pelo fato de ser capaz de descrever os padrões de ativação em espaços ortonormais entre os seus estados, o que demonstrou ser útil em aplicações de controle simultâneo utilizando sEMG. Em seu trabalho, (ARTEMIADIS & KYRIAKOPOULOS, 2009), apresentam o PCA utilizando sete canais de para o controle bidimensional antropomórfico de um robô através da análise das sinergias dos músculos decompostas através do PCA. Complementarmente, (MUCELI & FARINA, 2012), utilizaram o PCA para o controle de uma prótese mão-pulso com quatro graus de liberdade (GDL) utilizando entradas de mais baixa dimensionalidade baseadas em sinergia.

Métodos baseados em ICA são utilizados para projetar estatisticamente a sinergia de múltiplos canais de sEMG em função de cada músculo, independentemente. Avaliações deste tipo possibilitam avaliar a colaboração de cada músculo no sinal e são particularmente úteis quando se deseja eliminar algumas interferências indesejadas, como o *cross-talk* (STAUDENMANN, 2014). Em (NAIK, G. R.; BAKER, K. G., 2014) é apresentado um método baseado em ICA (SDICA) que realiza a decomposição do sinal em sub-bandas e que é capaz de identificar a dependência e independência de porções anteriores e posteriores da musculatura que é submetida a comandos simples e complexos de flexão dos dedos. Ainda em (NAIK, G. R.; DINESH, K., 2014) é descrito um método para separar diferentes aquisições de sEMG em um grupo de ações musculares independentes de modo a indicar a qualidade (contribuição) de cada canal posicionado sobre a pele do voluntário.

Já com a utilização do LDA (ZHANG & HUANG, 2015; LOCK *et al.*, 2005; JIANG, 2014) apresentam dados em função das sinergias das tarefas específicas realizadas pela musculatura que maximiza a variância no tempo entre tarefas. (CHEN *et al.*, 2010) utiliza cinco características distintas retiradas de sinais de sEMG para a classificação de nove movimentos de pulso. Em uma abordagem adaptativa no intuito de mitigar algumas



perturbações que contaminam o sinal de sEMG como eletrodos soltos e/ou mal contato, (ZHANG & HUANG, 2015) apresentam um algoritmo de LDA capaz de descartar características fornecidas com estas interferências em uma abordagem parecida com a proposta por (CENE *et al.*, 2015) e realizar um novo treinamento de alguns parâmetros específicos do modelo, propiciando um considerável ganho de tempo neste processo.

Embora o uso da Regressão Logística seja bastante difundido em áreas de estudo como saúde pública e ciências sociais, sua aplicação como classificador de sinais de sEMG não é tão explorada quanto outras técnicas. Um bom exemplo de aplicação desta técnica na área de processamento de sinais mioelétricos é relatado em (FARREL & WEIR, 2005), que apresentam a utilização da RL e dez eletrodos invasivos e seis não invasivos para classificar seis movimentos distintos do segmento mão-braço.

É comum em estudos publicados envolvendo a classificação de movimentos através de processamento de sinais de sEMG que seja utilizada mais de uma técnica no mesmo estudo a fim de avaliar o desempenho de cada método e validar resultados. (ATZORI, 2014) utilizam as técnicas de LDA, SVM, *k-Nearest Neighbors* e RNA para apresentar sua base de dados denominada NinaPro (*Non-Invasive Adaptive Hand Prosthetics*) e com ela fornecer uma atualização do estado da arte em *datasets* disponíveis online para o processamento de sinais de sEMG. Os resultados obtidos nestes estudo são descritos no Subcapítulo 5.9.

#### 4 METODOLOGIA EXPERIMENTAL

A Figura 22, apresenta o arranjo experimental, utilizado para a aplicação do método proposto, onde é possível visualizar os principais blocos do sistema que serão explicados detalhadamente ao longo deste capítulo.



**Figura 22 Diagrama de blocos do sistema proposto.**

A metodologia experimental pode ser dividida em duas abordagens. Quando os dados utilizados provêm da base de dados NinaPro (ATZORI, 2012), o sistema se resume as etapas de pré-processamento e de classificação do sinal, tendo em vista que as primeiras etapas já foram realizadas pela equipe que disponibiliza o banco de dados. Para os sinais de sEMG adquiridos no Laboratório IEE, o sistema é implementado em sua plenitude.

De forma geral, o sistema é constituído pelos seguintes blocos:

- um monitor posicionado em frente ao sujeito: permitindo que o sujeito acompanhe os movimentos realizados pelo braço virtual (nas etapas de treino e de aquisição de dados) replicando os movimentos mostrados neste monitor;


- dois eletromiógrafos comerciais, formando 12 canais para a captação dos sinais de sEMG através de eletrodos de superfície: 4 canais referentes ao posicionamento de eletrodos em músculos específicos e 8 canais referentes ao posicionamento dos eletrodos aleatoriamente distribuídos ao redor do braço direito de cada sujeito, para a captação do sinal mioelétrico durante a execução dos movimentos;
- uma plataforma dedicada à aquisição e digitalização dos dados, composta por uma placa de aquisição (NI USB-6289) da *National Instruments* conectada a um computador rodando o software *LabVIEW®* com a correspondente configuração dos parâmetros para a aquisição do sinal de sEMG;
- a etapa de pré-processamento: responsável pela segmentação e extração das características usadas como entradas do classificador;
- a etapa de classificação: método de inteligência computacional que consiste na implementação de um algoritmo de Regressão Logística para a classificação dos movimentos através da entrada composta pelas características do sinal escolhidas para servir de entrada ao método.

## **4.1 AQUISIÇÃO DE DADOS DA BASE DO LABORATÓRIO IEE**

### **4.1.1 Eletromiógrafo e eletrodos**

Eletromiógrafo é o equipamento que faz uso de eletrodos para captar sinais mioelétricos. O eletromiógrafo utilizado nesse trabalho para a aquisição do sinal mioelétrico foi utilizado por (LOPES, 2014). Neste trabalho, foi realizada a combinação de dois eletromiógrafos comerciais (EMG 830 C da EMG System do Brasil) de oito canais ligados em paralelo. Utilizando oito canais do primeiro EMG e quatro canais do segundo EMG, foi

possível montar uma plataforma capaz de capturar doze canais de sEMG. A captação do sinal é realizada através de eletrodos bipolares de configuração passiva (SOLIDOR, MSGST-06) e o arranjo de experimental utilizado é mostrado na foto da Figura 23.



**Figura 23** Foto Arranjo experimental utilizado na aquisição dos sinais: (1) monitor para a visualização dos movimentos; (2) arranjo dos dois eletromiógrafos utilizados; (3a, 3b e 3c) Cabos do eletromiógrafo: (a) 4 canais para posicionamento específico, (b) 8 canais para posicionamento aleatório e (c) eletrodos de referência; (4) eletrodos de superfície utilizados; (5) placa digitalizadora; (6) borneira e (7) computador utilizado.

A faixa do sinal de sEMG de interesse é compreendida entre 20 e 450 Hz em frequência e de 0 a 10mV em amplitude. Para realizar um condicionamento analógico e um primeiro tratamento do sinal, os eletromiógrafos comerciais utilizados possuem um filtro passa-banda de quarta ordem sintonizado na banda de frequência de interesse e um ganho total de 2000 vezes.

Para a aquisição e digitalização dos dados foi selecionada uma placa da *National Instruments* NI USB-6289 que possui 32 entradas analógicas e opera com 18 bits de quantização a um limite de 625 kS/s de digitalização. Para o presente trabalho, foi definida a frequência de amostragem em 2 kHz, a fim de manter o mesmo padrão da base de dados NinaPro que também é utilizada neste trabalho.

#### 4.1.2 Modelo virtual

Para a realização dos ensaios, este trabalho seguiu a metodologia sugerida por (FAVIEIRO, 2012 e LOPES, 2014) onde foi criado um modelo virtual de cada movimento, que tem como objetivo auxiliar a padronização dos ensaios para a aquisição do sinal muscular. Observando o modelo virtual, o usuário é capaz de visualizar e repetir o movimento mostrado no monitor, o que possibilita a todos os voluntários realizar, da melhor forma possível, os mesmos movimentos e de onde foi retirado o *timestamp* utilizado na segmentação do sinal. Para o desenvolvimento do modelo virtual foram utilizados os softwares MakeHuman 1.0.2 e Blender 2.75a.

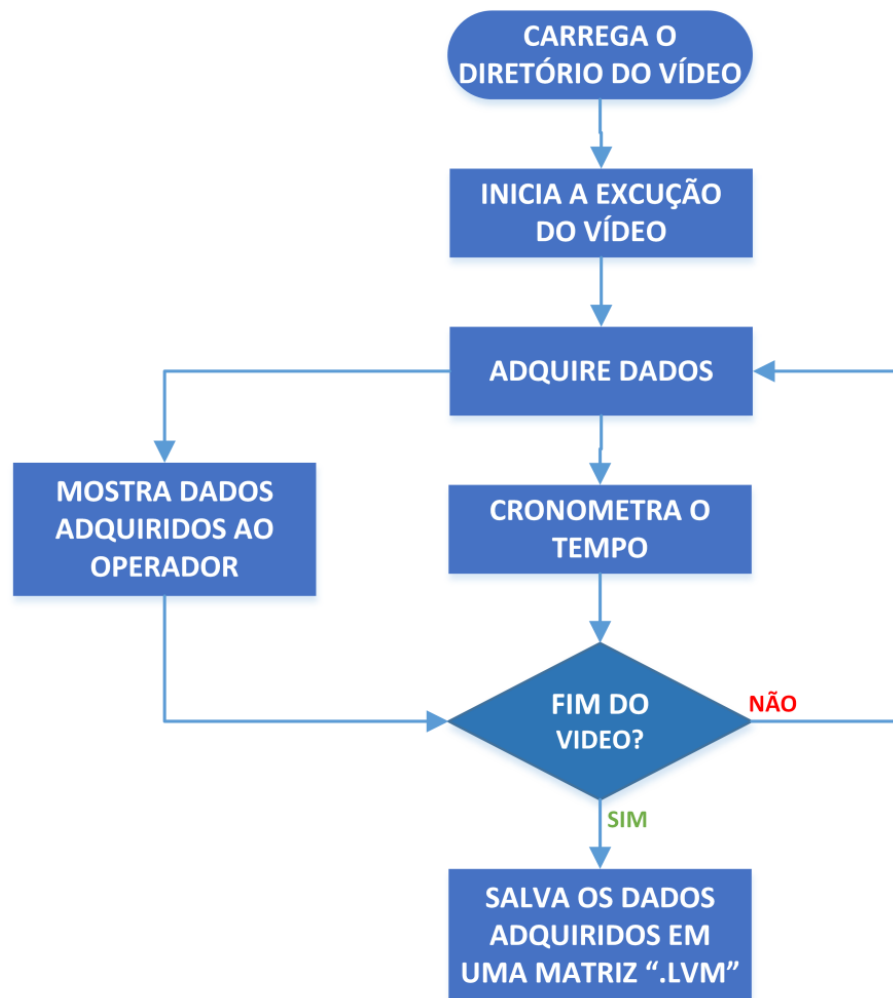
O processo de criação das animações que são expostas aos voluntários, consiste em utilizar o MakeHuman para a definição dos parâmetros do modelo humanóide a ser gerado (altura, peso, sexo, etc...). Uma vez gerado o modelo, é criado um arquivo de extensão “.dae” que serve de entrada para o Blender.

No Blender este arquivo é lido e é criado um esqueleto cujas articulações manipuláveis são utilizadas para definir as posições que o mesmo deve assumir em certo momento. Através da variação adequada desse modelo no tempo, são criadas as animações. Para tanto são definidas posições iniciais e finais em certa base de tempo. A animação em si, consiste do software ligando uma posição à outra. Também foi estabelecida uma posição de repouso que foi adotada para todos os movimentos. Desta forma, todos os movimentos partem da posição de repouso, são executados (animação do movimento de interesse) e retornam à posição de repouso. A geração das animações foi realizada por uma aluna de doutorado do Laboratório de Instrumentação Eletro-Eletrônica (IEE) do Programa de Pós-Graduação em Engenharia Elétrica (PPGEE) da UFRGS.

Para apresentar as animações criadas para o usuário do sistema, um bolsista de Iniciação Científica do Laboratório IEE desenvolveu uma rotina no LabVIEW® capaz de realizar a leitura dos arquivos de animação gerados no Blender. Ao total, dois vídeos foram gerados no Blender, um destinado a ser exibido durante o treinamento e um segundo a ser exibido durante a aquisição dos sinais. O fluxograma da Figura 24, apresenta o fluxograma do programa desenvolvido em LabVIEW. Os programas desenvolvidos em LabVIEW são apresentados no APÊNDICE A deste trabalho. Os sinais adquiridos na etapa de treinamento servem para efetuar a supervisão do sistema a fim de conferir se todos os sinais estão sendo adequadamente adquiridos e se não há a ocorrência de eletrodos soltos ou mal posicionados que possam prejudicar a aquisição dos sinais.

É válido ressaltar que, embora os sinais sejam conferidos na etapa de treino, não são impedidos problemas como eletrodos soltos ou uma má realização do movimento proposto durante o restante da etapa de ensaios. Este procedimento é devido à filosofia de trabalho do grupo de pesquisa onde é assumido que estes são cenários de uma aplicação do dia a dia. Portanto, o sistema desenvolvido deve ser capaz de lidar com estes cenários.

As duas rotinas desenvolvidas em LabVIEW diferem somente na leitura do vídeo criado com o Blender. No vídeo de treino, são realizadas três repetições, no vídeo de aquisição, seis. Enquanto o voluntário acompanha o vídeo, reproduzindo o movimento a ser realizado, o operador do sistema visualiza a janela de programação do LabVIEW em um computador portátil, onde são mostrados os sinais que estão sendo adquiridos durante os ensaios (FAVIEIRO, 2012). Para maiores detalhes a respeito da criação dos movimentos virtuais é sugerida a consulta a (FAVIEIRO, 2012).



**Figura 24 Fluxograma da rotina de visualização das animações e aquisição de dados.**

#### **4.1.3 Procedimentos Para a Realização dos Ensaios de Aquisição de Dados**

A primeira etapa ao se realizar ensaios com seres humanos consiste na apresentação e explicação de um Termo de Livre Consentimento que relata o experimento e os potenciais riscos aos quais os voluntários ficam submetidos caso aceitem participar dos ensaios. O termo de consentimento padrão é ilustrado no APÊNDICE B. A seguir, é realizada uma breve anamnese, para se ter conhecimento de algumas características relevantes do Voluntário, para uma análise mais precisa dos resultados. A anamnese utilizada encontra-se no APÊNDICE C. Este trabalho faz parte do projeto aprovado pelo Comitê de Ética CAAE: 11253312.8.0000.5347.

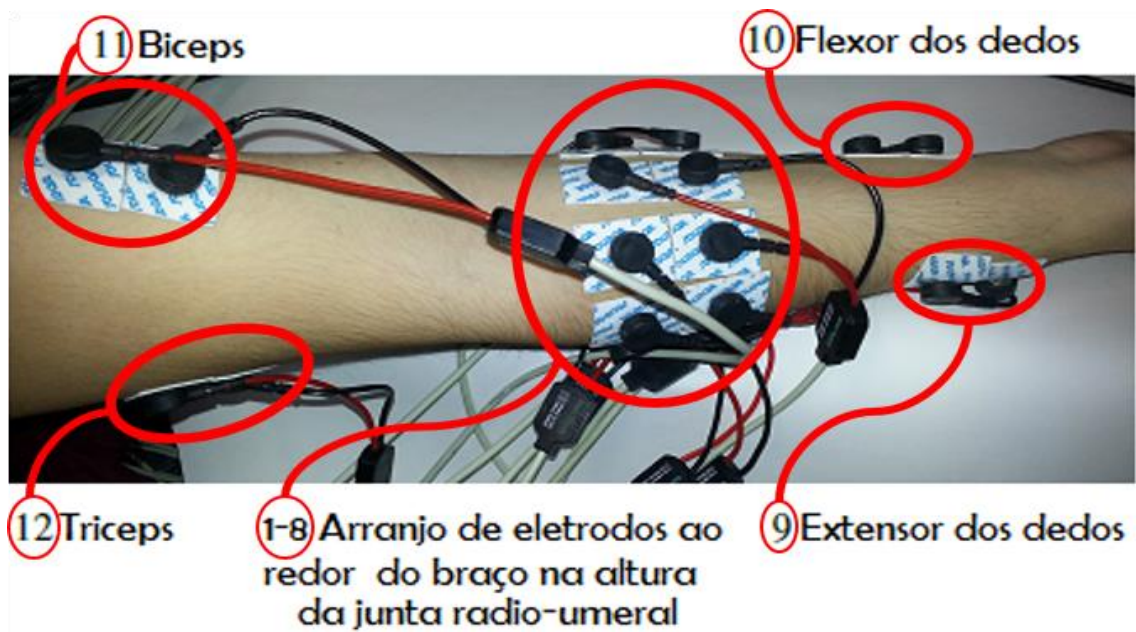
Os ensaios para aquisição de dados foram realizados a fim de obter o sinal muscular mais fidedigno possível. A metodologia para o posicionamento dos eletrodos segue a descrita por (FAVIEIRO, 2012) e consiste em:

- limpar a pele onde os eletrodos foram posicionados;
- posicionar o eletrodo na parte ventral do músculo que se quer analisar;
- posicionar o eletrodo de forma que os cabos de aquisição dos dados não atrapalhem o movimento do braço;
- fixar os cabos de aquisição de modo que eles não se movimentem durante os ensaios, principalmente na parte do cabo próxima aos eletrodos.

O sistema descrito neste trabalho visa determinar se o músculo analisado está realizando um movimento e optou-se por não realizar a raspagem dos pelos e o lixamento da pele, bastando uma boa limpeza para a aquisição de um sinal com uma relação sinal-ruído adequada (em torno de 800). O eletrodo de referência, geralmente fica localizado na parte central da testa ou no lóbulo da orelha. Por praticidade, neste trabalho, os eletrodos de referência - um para cada eletromiógrafo - foram posicionados na testa, por ser um local de mais fácil fixação.

Para a aquisição dos dados foi utilizada a placa de aquisição NI USB-6289. Foram utilizados 12 pares de eletrodos localizados nos grupos musculares de interesse no braço do voluntário. Dos 12 pares, 8 foram posicionados em um arranjo equidistante na altura da junta rádio-umeral do voluntário. Os 4 pares de eletrodos restantes, foram posicionados sobre os seguintes músculos específicos: Extensor dos dedos; Flexor profundo dos dedos; Bíceps e Tríceps. A foto da Figura 25 ilustra o posicionamento dos eletrodos.





**Figura 25 Foto do posicionamento dos eletrodos.**

O processo de aquisição é iniciado a partir do início do vídeo do primeiro movimento, que assim como os subsequentes, é replicado simultaneamente pelo usuário que acompanha os movimentos no monitor auxiliar específico. O voluntário é instruído a replicar as animações do modelo virtual utilizando força moderada (é importante ressaltar que neste trabalho não foi realizado o monitoramento da força aplicada pelo voluntário e nem usado qualquer procedimento de realimentação). A padronização dos ensaios seguiu o modelo da base NinaPro (ATZORI, 2012), que é definido conforme as seguintes diretrizes:

- um ensaio formado por uma sessão;
- cada sessão contém 102 movimentos;
- os 102 movimentos são compostos por 6 repetições consecutivas de 17 movimentos distintos;
- cada movimento é realizado em um período de 5 segundos intercalado por pausas de 3 segundos para descanso do voluntário.
- para a aquisição dos sinais de sEMG no Laboratório IEE, cada voluntário participou de 3 ensaios de forma aleatorizada.

O tempo de repouso é muito importante para minimizar possíveis fadigas dos músculos durante o ensaio. Cada ensaio tem duração aproximada de 13 minutos, embora quando somado a este tempo a preparação do voluntário e a montagem do aparato experimental, o tempo total do ensaio pode alcançar aproximadamente uma hora de duração. A Figura 26 ilustra uma sessão realizada com um voluntário.



**Figura 26** Foto da realização de um dos ensaios.

#### **4.2 DESCRIÇÃO DA BASE DE DADOS NINAPro**

Na base de dados NinaPro, a atividade muscular foi adquirida através de um arranjo de 12 eletrodos de sEMG *wireless* não invasivos. Cada um dos eletrodos é equipado com uma bateria recarregável e possui um alcance de 40m em sua área de cobertura. Os dados foram digitalizados através da plataforma NI-DAQ PCMCIA 6024E da *National Instruments* a uma taxa de 2 kHz e 12 bits, com um ruído de 750nV (ATZORI, 2014).

### 4.3 MOVIMENTOS REALIZADOS NOS ENSAIOS

Os movimentos realizados nos ensaios são comuns às duas bases de dados (IEE e NinaPro). Estes movimentos perfazem um total de 102 movimentos, constituídos por 6 repetições de 17 movimentos distintos. As repetições são realizadas sequencialmente englobando os movimentos de 1 a 17. Os movimentos alvos da classificação neste trabalho e a sua respectiva ordem são ilustrados na Figura 27.

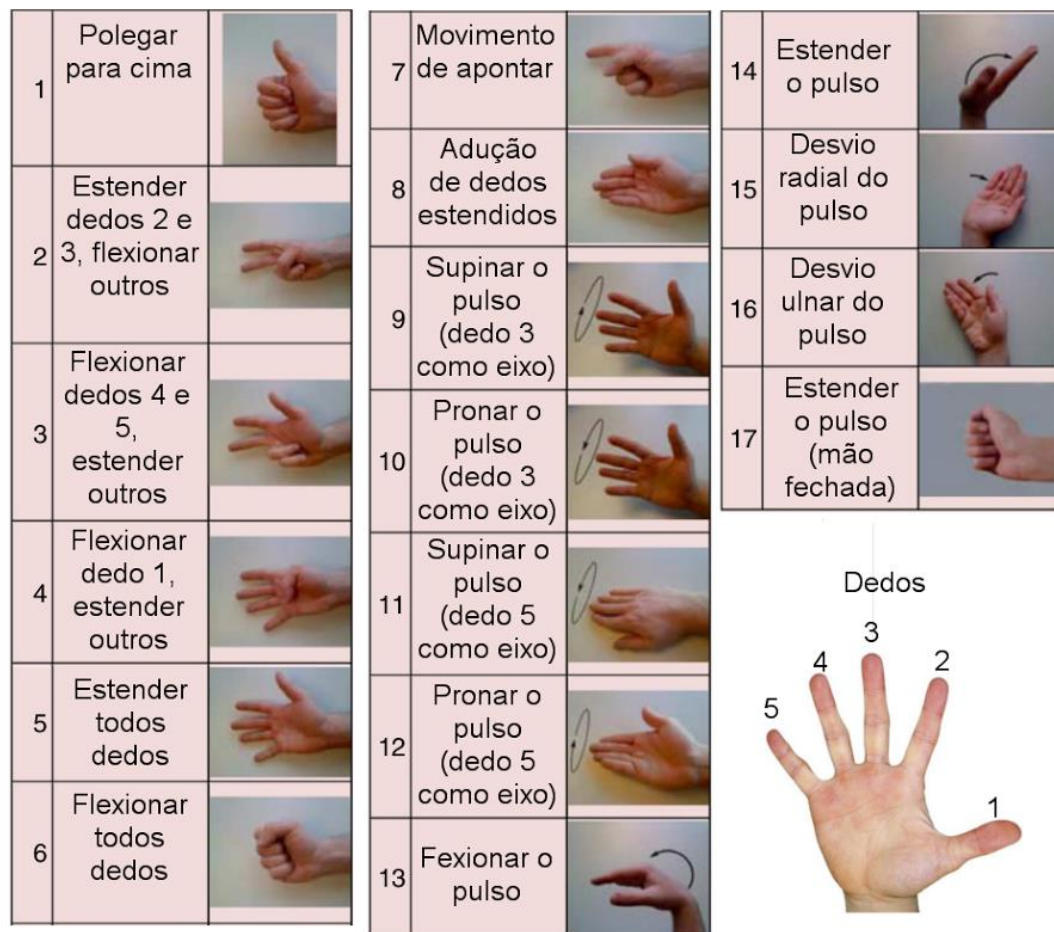


Figura 27 Movimentos alvo de classificação (adaptado livremente de ATZORI, 2014).

### 4.4 PROCESSAMENTO DOS BIOSINAIS

É importante ressaltar que a base de dados NinaPro possui um total de 51 voluntários (40 não-amputados e 11 amputados) e que, neste estudo foram utilizados 30 voluntários não amputados e 10 amputados. Adicionalmente foram processados mais 10 sinais de voluntários

não amputados adquiridos no Laboratório IEE para formar a base de dados total que compõe esse estudo. A Tabela 3 apresenta as bases de dados e número de voluntários utilizados neste trabalho.

**Tabela 3 Divisão dos grupos de dados utilizados na classificação de movimentos.**

Pacote de dados	Número de voluntários
<b>NinaPro – Não-amputados</b>	30 voluntários
<b>NinaPro – Amputados</b>	10 voluntários
<b>Dados obtidos no Laboratório IEE</b>	10 voluntários

Uma vez adquiridos, os sinais passam pelas etapas de processamento onde são realizadas diversas operações e finalmente as características são extraídas e inseridas como variáveis de entrada no classificador para posterior análise dos resultados.

Todos os algoritmos de processamento foram desenvolvidos através do MATLAB 2014a® (MathWorks). O desenvolvimento de cada bloco e seus fluxogramas são detalhados nas respectivas seções. Após os dados serem pré-processados, a classificação dos sinais é realizada e os resultados são salvos em matrizes de confusão e tabelas que são utilizadas no pós-processamento para análise dos resultados.

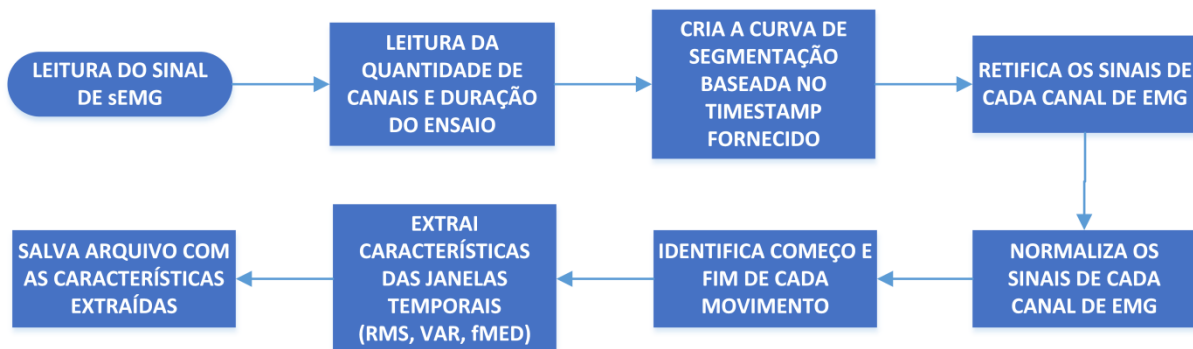
#### **4.4.1 Pré-processamento**

A etapa de pré-processamento tem por objetivo realizar a segmentação do sinal, realizar a retificação e a normalização do sinal, extrair as características que servem como entrada do algoritmo de inteligência computacional e salvar os dados de forma separada e organizada para cada sujeito, deixando-os prontos para o processo de classificação.

##### **4.4.1.1 Segmentação da base de dados NinaPro**

A base de dados NinaPro contém um *timestamp* que fornece o tempo no qual cada movimento foi realizado. O *timestamp* foi definido em função da duração dos vídeos dos

movimentos utilizados nos ensaios e do programa de aquisição. Através do *timestamp* fornecido foi criada uma curva de segmentação – detalhada no Subcapítulo 4.4.1.2 - que foi utilizada para separar os períodos de movimentos e intervalos durante a realização dos ensaios. A Figura 28 apresenta de forma simplificada o processo utilizado para segmentação e extração de características do sEMG baseando-se no *timestamp*.



**Figura 28 Segmentação e extração de características do sinal.**

A abordagem da segmentação dos sinais utilizando o *timestamp* é particularmente útil por fornecer um sinal sem perdas para a etapa de extração de características, o que permite avaliar melhor o desempenho do algoritmo de IC em si, uma vez que as características são extraídas de um sinal próximo ao ideal e sem problemas de segmentação.

#### 4.4.1.2 Segmentação da base de dados adquirida no Laboratório IEE

Para minimizar o nível de ruído medido através da média da componente DC presente no sinal para esta base (aproximadamente  $800\mu\text{V}$ ), foi aplicado um filtro digital passa-faixa de ordem 20. O filtro FIR (*Finite Input Response*) desenvolvido é sintonizado na faixa de 20 a 500 Hz e possui frequência de amostragem de 2 kS/s.


O procedimento de segmentação da base de dados do Laboratório IEE seguiu a mesma metodologia da base de dados NinaPro onde foi utilizado um *timestamp* gerado durante a etapa de aquisição do sinal para a geração da curva de segmentação.

A curva de segmentação consiste em uma onda quadrada de níveis zero e um. No tempo previsto para cada um dos movimentos a curva tem valor um e nas condições de descanso, possui valor zero. Após a definição desta curva é realizada a segmentação do sinal de sEMG, demonstrada na Equação (26), o que resulta no valor do sinal de sEMG para o tempo que compreende o movimento e em nível zero para as condições de descanso.

$$sEMG_{SEG}(t) = EMG(t) \cdot Seg(t) \quad (26)$$

onde  $EMG(t)$  representa os vetores (de 12 canais) do sinal de sEMG de entrada;  $Seg(t)$  representa o vetor contendo a curva de segmentação gerada e  $sEMG_{SEG}(t)$ : representa o sinal resultante, que consiste no sinal de cada canal segmentado.

A Figura 29 apresenta apenas como exemplo, o processo de segmentação empregado na etapa de pré-processamento. Nela é possível observar uma parcela de um canal adquirido sem processamento, a curva de segmentação e o resultado da operação realizada. Na Figura 29 a curva de segmentação teve sua amplitude reduzida por mera questão de melhor visualização.



**Figura 29** Exemplo do procedimento de segmentação baseada em *timestamp*.

#### 4.4.1.3 Retificação e normalização do sinal de sEMG

Como já explicitado na introdução deste trabalho, a utilização de dados de entrada com um menor *range* de excursão favorece o desempenho do classificador, para tanto o sinal é retificado e normalizado antes que as características sejam extraídas.

A retificação provê a obtenção de um sinal de sEMG exclusivamente positivo, esta operação é facilmente realizável através do cálculo do módulo do sinal (Equação (27)). Neste trabalho foi utilizada a retificação de onda completa. Todos os valores negativos do sinal de sEMG foram então, rebatidos para valores acima de zero.

$$sEMG_{RET}(t) = |sEMG_{SEG}(t)| \quad (27)$$

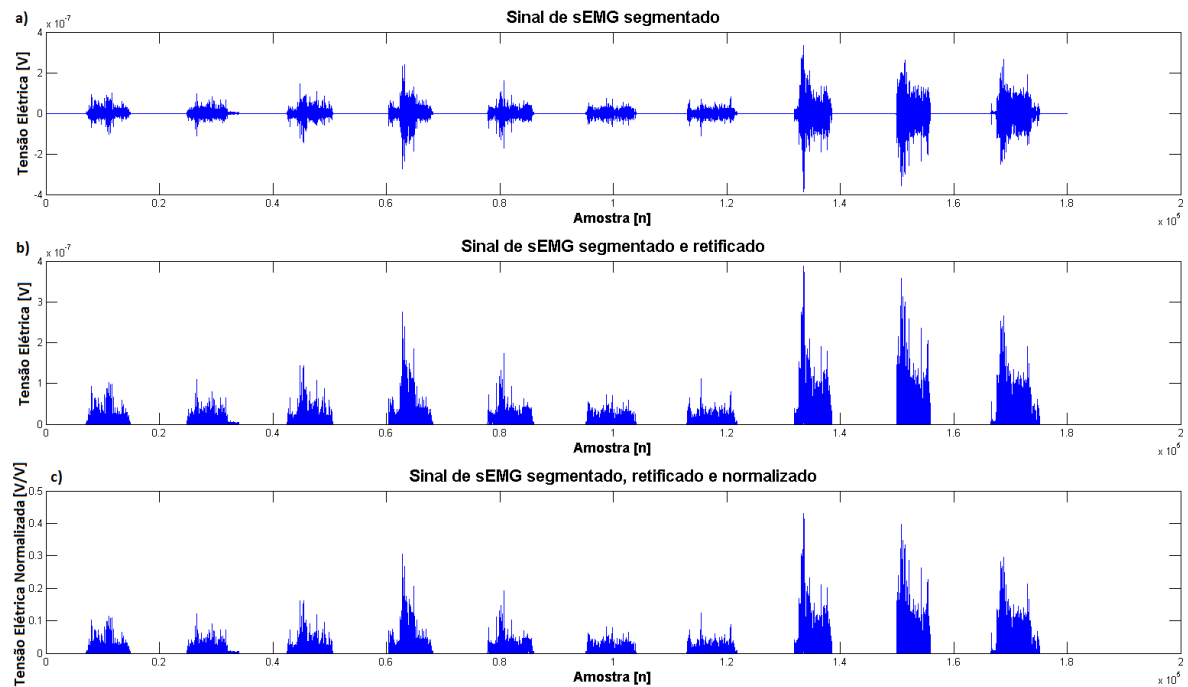
Sendo  $sEMG_{SEG}(t)$  o sinal de sEMG de doze canais segmentado de entrada e  $sEMG_{RET}(t)$  o equivalente sinal retificado de sEMG.

Em relação à normalização do sinal, em seu estudo (HSU *et al.*, 2003) ressaltam a importância de escalonar os dados antes de usá-los como entrada de um método de IC. A principal vantagem é evitar atributos que possuam valores muito altos ou muito discrepantes e que influenciem em demasia os coeficientes do classificador. Isto ocorre porque os valores dos coeficientes do método de IC dependem dos produtos internos dos vetores de características, como explicado na introdução deste trabalho. Para o escalonamento dos dados é utilizada então, a normalização dos sinais de sEMG por canal, conforme a Equação 28.

$$sEMG_{CANAL\_NORM}(t) = \frac{sEMG_{RET}(t)}{\max(|sEMG_{RET}(t)|)} \quad (28)$$

Onde  $sEMG_{RET}(t)$  representa o sinal de sEMG segmentado e retificado de entrada por canal e  $sEMG_{CANAL\_NORM}(t)$  representa o respectivo sinal de sEMG normalizado por canal.

Como exemplo, a Figura 30 ilustra o sinal de sEMG segmentado, o sinal retificado ( $sEMG_{RET}$ ) e finalmente o sinal normalizado ( $sEMG_{CANAL\_NORM}$ ) do nono canal de um sinal extraído de um dos voluntários da base de dados NinaPro.



**Figura 30** Exemplo de parte de um arquivo de dados adquirido e o tratamento de dados utilizado na segmentação por timestamp: a) sinal de sEMG após a segmentação, b) sinal de sEMG após a segmentação e retificação, c) sinal de sEMG após a segmentação, retificação e normalização.

#### 4.4.1.4 Extração de características

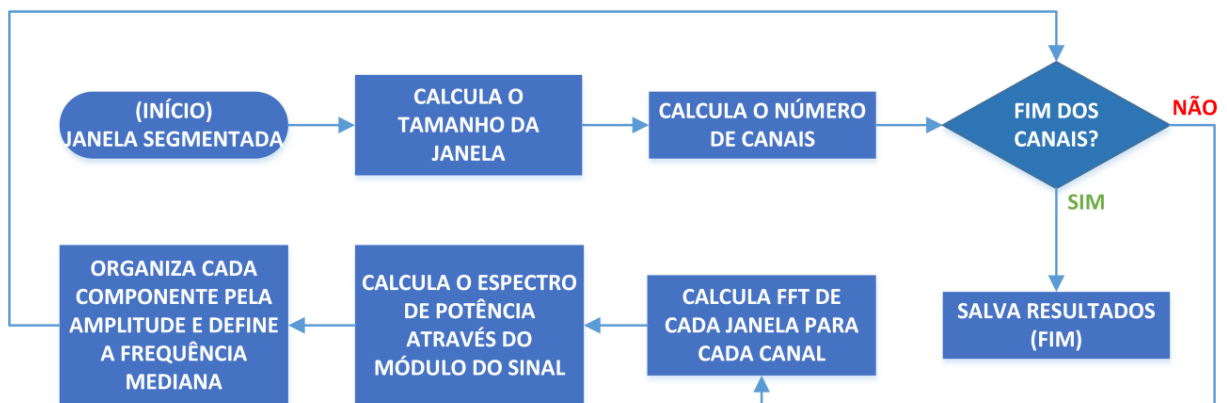
Após a segmentação dos sinais de sEMG, obtém-se a janela correspondente a cada movimento. Desta janela são retirados parâmetros que servem como entrada para o treino dos modelos de Regressão Logística. Os parâmetros (ou características) extraídos da janela segmentada e utilizados como entradas foram: o valor RMS (Equação (29)), a variância (Equação (30)) e a frequência mediana (ver fluxograma da Figura (31)) de cada janela segmentada. Estes parâmetros foram escolhidos (dentre outros) com base na taxa de acerto mais alta que ofereceram em testes preliminares.

$$RMS(sEMG_{CANAL\_NORM}(x)) = \sqrt{\frac{1}{N} \sum_{t=1}^N sEMG_{CANAL\_NORM}(t)^2} \quad (29)$$

$$\sigma^2(sEMG_{CANAL\_NORM}(x)) = \frac{1}{N} \sum_{t=1}^N \left( |sEMG_{CANAL\_NORM}(t) - \overline{sEMG_{CANAL\_NORM}(t)}| \right)^2 \quad (30)$$



Onde  $sEMG_{CANAL\_NORM}(t)$  representa sinal de sEMG normalizado por canal,  $RMS(sEMG_{CANAL\_NORM}(x))$  representa o valor quadrático médio (*Root Mean Square*) calculado para a janela segmentada de N amostras de interesse e  $\sigma^2(sEMG_{CANAL\_NORM}(x))$  representa o valor da variância calculado para a janela segmentada de N amostras de interesse.



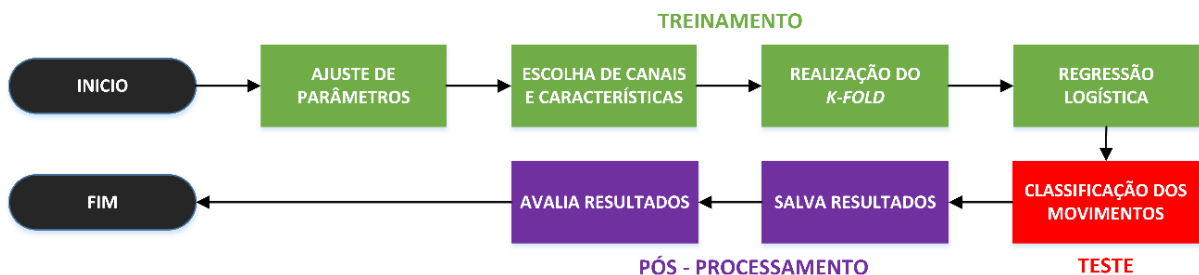
**Figura 31** Extração da frequência mediana da janela de segmentação.

No procedimento representado na Figura 31 o Cálculo do tamanho da janela considera a contagem de amostras por janela; por canal e o Cálculo do número de canais consiste na contagem de colunas da matriz de entrada, onde cada uma representa um canal. O Cálculo da FFT consiste na aplicação da Transformada Rápida de Fourier em cada janela segmentada, o módulo do espectro de potência é o cálculo do módulo da FFT e a Organização consiste na ordenação de valores de modo a isolar o componente referente a frequência mediana do sinal. Ao final do algoritmo o valor da frequência mediana isolada para cada canal de cada janela é salvo em uma matriz de saída. Posteriormente estes valores são todos unidos juntos as outras características e salvos ordenadamente para cada voluntário para formar o banco de dados de características que são utilizados posteriormente como dados de entrada do algoritmo de classificação.

#### 4.4.2 Processamento do sinal de sEMG

Após a extração das características, as mesmas são automaticamente salvas em arquivos “.mat”. A leitura destes arquivos é realizada pelo programa desenvolvido em MATLAB. Estes valores das características são utilizados como parâmetros de entrada do modelo da RL.

O classificador desenvolvido se apoia na técnica de Regressão Logística Binomial. O sistema desenvolvido é flexível e modular, capaz de se adaptar às diferentes combinações de canais e características de entrada utilizadas. Os diferentes módulos são detalhados a seguir. A Figura 32 apresenta o diagrama de blocos principal do programa desenvolvido para as etapas de treino e teste do classificador.




**Figura 32 Diagrama de blocos simplificado do programa desenvolvido.**

Para a classificação dos sinais, é realizada a leitura de cada matriz de características de entrada para cada sujeito. Após a leitura das matrizes são inicializados os valores de  $\alpha$  e  $\lambda$  (representados na Equação (20)) e são chamados os métodos de treino e de classificação. Através da variação iterativa dos valores de  $\alpha$  e  $\lambda$  (parâmetros de *fitting*) é possível atingir uma situação de melhor adequação do modelo a cada base de dados de cada voluntário e assim atingir uma taxa de acerto maior devido ao melhor ajuste.

#### 4.4.2.1 Ajuste dos parâmetros de *alpha* e *lambda*

A definição dos parâmetros de *tunning* (ajuste fino) do modelo foi realizada através de teste em função da taxa de acerto para cada voluntário. Desta forma, foram testados 100 valores diferentes para cada um dos parâmetros.


Posteriormente foi avaliado qual valor fornecia a maior taxa de acerto para cada modelo. A Figura 33 apresenta os resultados obtidos para os testes do valor de *alpha* do voluntário 01 da base NinaPro na condição de classificação utilizando 8 canais e somente a característica de *RMS*.



**Figura 33 Exemplo de variação do parâmetro *alpha*.**

Os parâmetros permitem um melhor condicionamento do modelo aos sinais de entrada independentemente do número de canais e características de entrada, portanto foi utilizado o número mínimo de canais e características para o teste a fim de permitir ganho de tempo (tendo em vista que mais dados de entrada exigem mais capacidade de processamento e conseqüentemente maior consumo de tempo).

Assim, como a Figura 33, apresenta a taxa de acerto obtida em função da variação do parâmetro *alpha*, a Figura 34 mostra os testes realizados em função do parâmetro *lambda*.



**Figura 34 Exemplo de variação do parâmetro lambda.**

Os testes foram realizados para todos os voluntários de forma a se atingir valores mais propícios para os modelos. Quanto a faixa numérica de teste coberta, para os dados provenientes de voluntários não amputados da base NinaPro foram utilizadas as mesmas escalas para os parâmetros, onde ambos sofrem um total de até 100 iterações. Já para os dados de voluntários amputados da base NinaPro e para os dados adquiridos no Laboratório IEE o parâmetro lambda foi utilizado em uma escala dez vezes menor. Esta decisão foi tomada após a observação dos resultados expostos na Figura 34, que parecem apontar que um valor alto estava sendo utilizado pelo fato de a primeira iteração fornecer o melhor resultado e as subsequentes um resultado muito ruim. A variação adotada para *alpha* em todas as bases de dados é dada pela Equação (31). Já para a variação de *lambda* utilizando a base de não amputados NinaPro tem-se uma variação proposta pela Equação (32) e para a base NinaPro amputados e base do IEE, pela Equação (33). As faixas de valores foram estabelecidas com base em testes preliminares realizados.

$$\alpha [i] = 0,005 \times i \quad (31)$$

$$\lambda (n.a.) [i] = 0,005 \times i \quad (32)$$

$$\lambda [i] = 0,0005 \times i \quad (33)$$

Onde:  $i$  corresponde ao número da iteração e  $\alpha [i]$  corresponde ao novo valor de  $\alpha$  para a nova classificação. Já  $\lambda (n.a.)[i]$  corresponde ao novo valor de  $\lambda$  para a nova classificação dos sujeitos não amputados da base NinaPro e  $\lambda [i]$  corresponde ao novo valor de  $\lambda$  para a nova classificação dos sujeitos amputados da base NinaPro e voluntários da base adquirida no laboratório IEE.

Desta forma a faixa numérica coberta pela variação de  $\alpha$  é de 0,005 até 0,500. Já para  $\lambda$  tem-se uma variação de valor igual para os não amputados da base NinaPro e uma variação de 0,0005 até 0,0500 para as bases NinaPro amputados e IEE. A Tabela 4 apresenta os melhores parâmetros encontrados em função da taxa de acerto para cara voluntário. Esses valores foram utilizados como parâmetro para a classificação de movimentos para cada voluntário.

**Tabela 4 Valores de  $\alpha$  e  $\lambda$  obtidos para os voluntários.**

Voluntário	$\alpha$	$\lambda$
<b>NinaPro – Não-amputados</b>		
1	0,150	0,005
2	0,100	0,005
3	0,100	0,005
4	0,100	0,005
5	0,100	0,005
6	0,050	0,005
7	0,050	0,005
8	0,100	0,005
9	0,100	0,005
10	0,150	0,005
11	0,150	0,005
12	0,100	0,005
13	0,150	0,005
14	0,050	0,005
15	0,050	0,005
16	0,050	0,005
17	0,150	0,005
18	0,100	0,005
19	0,100	0,005
20	0,150	0,005
21	0,150	0,005
22	0,100	0,005
23	0,050	0,005

*Continuação da Tabela 4.*

24	0,100	0,005
25	0,100	0,005
26	0,100	0,005
27	0,100	0,005
28	0,050	0,005
29	0,100	0,005
30	0,150	0,005
<b>NinaPro – Amputados</b>		
1	0,100	0,0010
2	0,100	0,0015
3	0,050	0,0015
4	0,050	0,0005
5	0,050	0,0005
6	0,050	0,0005
7	0,100	0,0005
8	0,100	0,0005
9	0,100	0,0005
10	0,050	0,0005
<b>IEE</b>		
1	0,100	0,0005
2	0,050	0,0005
3	0,100	0,0005
4	0,100	0,0005
5	0,050	0,0005
6	0,150	0,0005
7	0,100	0,0005
8	0,050	0,0005
9	0,100	0,0005
10	0,100	0,0005

#### 4.4.2.2 Variação dos dados de entrada

Após definidos os coeficientes mais favoráveis à criação do modelo é realizado o processo de separação dos dados para o treino e teste variando o número de canais e o número de características. O diagrama de blocos da organização dos dados de entrada pode ser visualizado na Figura 35.

O primeiro passo consiste na limpeza do ambiente do Matlab sucedido pela identificação do sujeito e a leitura do arquivo de entrada. Após a leitura da matriz de entrada é realizada a organização da base de dados para o treino do modelo de cada voluntário. O arquivo de entrada que originalmente é uma matriz como a apresentada na Tabela 5 de 102

(número de movimentos realizados) x 36 (três características para cada um dos doze canais) é decomposto em função do número de características e canais utilizados para a criação de cada modelo.

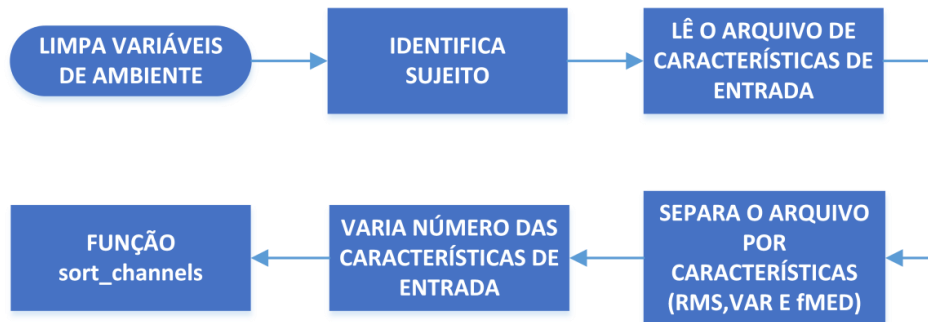


Figura 35 Fluxograma da função Main\_test.

**Tabela 5 Matriz 102x36 representativa de entrada para a etapa de treinamento da regressão logística: em verde a seção de 102x12 correspondente a característica RMS, em amarelo a seção de mesmo tamanho representando a variância e em azul a última seção representando a frequência mediana para todos os movimentos realizados.**

Entrada 1	...	Entrada 12	Entrada 13	...	Entrada 24	Entrada 25	...	Entrada 36
M 1	M 1	M 1	M 1	M 1	M 1	M 1	M 1	M 1
M 2	M 2	M 2	M 2	M 2	M 2	M 2	M 2	M 2
.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.
M 102	M 102	M 102	M 102	M 102	M 102	M 102	M 102	M 102

As variações das características de entrada ocorrem conforme a Tabela 6. Desta forma são realizados todos os cenários de combinações possíveis com as três características a fim de se averiguarem os efeitos destas combinações na classificação.

Para cada combinação de características de entrada é realizada uma variação dos canais de entrada utilizados. As combinações dos canais foram realizadas de tal forma a manter o agrupamento dos eletrodos distribuídos aleatoriamente sempre juntos e avançar progressivamente adicionando canais à classificação, conforme apresentado pela Tabela 7.

**Tabela 6** Combinações de características de entradas utilizadas.

<b>Instância</b>	<b>Característica utilizada</b>
<b>1</b>	<b>RMS</b>
<b>2</b>	<b>VAR</b>
<b>3</b>	<b>fMED</b>
<b>4</b>	<b>RMS + VAR</b>
<b>5</b>	<b>RMS + fMED</b>
<b>6</b>	<b>VAR + fMED</b>
<b>7</b>	<b>RMS + VAR + fMED</b>

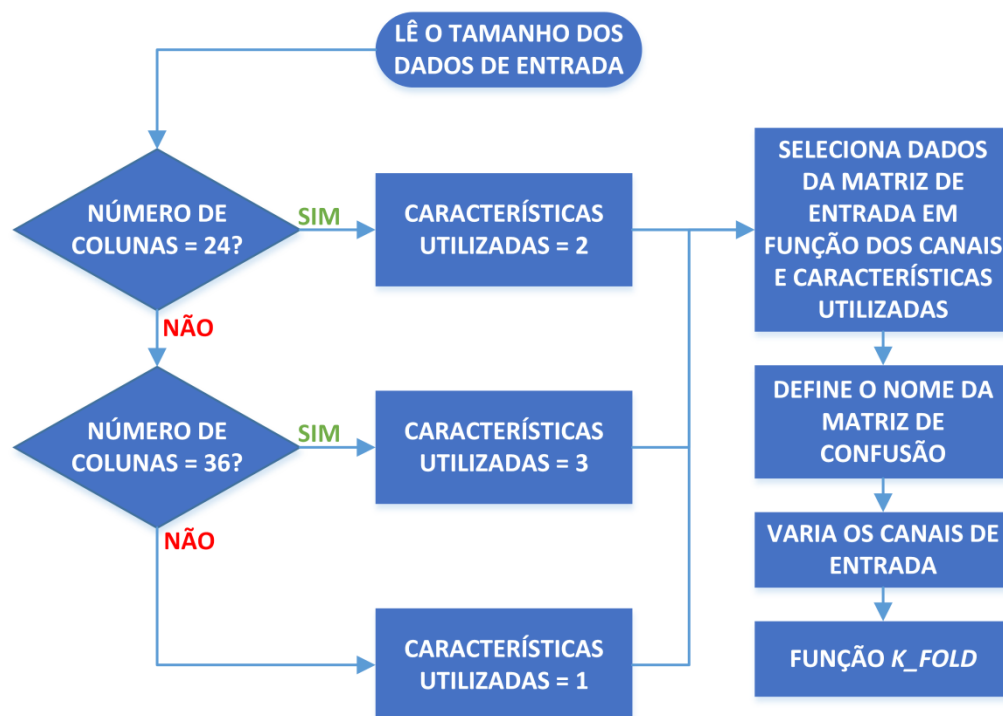
**Tabela 7** Combinações de canais de sEMG utilizados para cada entrada gerada pela variação das características de entrada utilizadas.

<b>Instância</b>	<b>Canais utilizados</b>
<b>1</b>	<b>1 ao 8</b>
<b>2</b>	<b>1 ao 8 e 9</b>
<b>3</b>	<b>1 ao 8 e 10</b>
<b>4</b>	<b>1 ao 8 e 11</b>
<b>5</b>	<b>1 ao 8 e 12</b>
<b>6</b>	<b>1 ao 9 e 10</b>
<b>7</b>	<b>1 ao 9 e 11</b>
<b>8</b>	<b>1 ao 9 e 12</b>
<b>9</b>	<b>1 ao 10 e 11</b>
<b>10</b>	<b>1 ao 10 e 12</b>
<b>11</b>	<b>1-12</b>

Uma vez definidas as características e canais a serem utilizados o próximo passo consistiu em dividir o banco de dados disponível em instâncias de treino e teste. Desta forma, foram seleccionadas quatro das seis repetições (66,7% do *dataset*) para o treino do modelo e



duas (33,3% do *dataset*) para teste, realizando um *k-fold* com  $k=6$ , assim é possível testar a robustez do método frente a diferentes repetições dos movimentos. Existem alguns fatores que podem afetar a morfologia e consequentemente a classificação do sinal como fadiga do sujeito (principalmente nas últimas repetições) e a falta de treino (principalmente nas primeiras repetições). O *k-fold* surge como opção para variar as repetições com as quais o modelo é criado (treinado) e testado. Desta forma, são realizados testes nas diferentes condições de entradas. Para o treino e para o teste são utilizadas as características e canais previamente estabelecidos. A Figura 36 apresenta o fluxograma simplificado da função que realiza a ordenação dos dados, criação da matriz de confusão e realiza a chamada do método de *k-fold*. A Figura 37 apresenta o *k-fold* realizado em função das repetições dos movimentos e a Figura 38 o seu respectivo algoritmo.

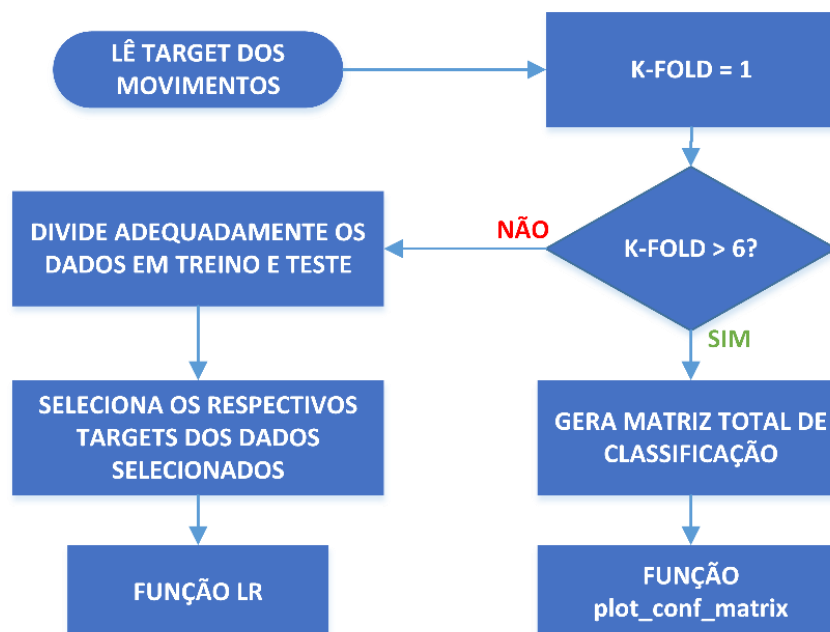


**Figura 36 Fluxograma da função de ordenação dos dados de entrada.**



**Figura 37 k-fold realizado.**


Neste mesmo segmento do programa desenvolvido se dá a criação e a nomeação da matriz de confusão que posteriormente será utilizada para o cálculo das taxas de acerto das classificações dos movimentos. Cada instância de *k-fold* utiliza duas repetições dos movimentos realizados (fundo laranja na Figura 37) para o teste do método, ao fim do *k-fold* com  $k=6$  tem-se 12 resultados de teste para cada movimento. Desta forma é possível organizar o treino e o teste do classificador de cada movimento.



**Figura 38 Fluxograma da função responsável pelo k-fold.**

#### 4.4.2.3 Definição do modelo de Regressão Logística

Após a organização e seleção das características, canais e repetições a serem utilizadas o algoritmo de treino é executado. O diagrama de blocos simplificado da função responsável pela geração dos modelos de Regressão Logística é apresentado na Figura 39.



**Figura 39 Fluxograma da função LR.**

Neste estágio é realizada a verificação do tamanho da matriz de dados de entrada e calculado o número de séries de repetição de teste. Sequencialmente são montadas as matrizes de treino e de teste e também definidos os valores iniciais (zero) dos coeficientes utilizados no treino do classificador e realizada uma nova normalização dos dados de entrada por canal conforme representado pela Equação (23). Esta nova normalização tem por objetivo oferecer uma maior discrepância entre os valores numéricos e com isso tornar cada dado mais representativo, este passo é apresentado na Figura 40.

Após a separação e adequação dos valores de treino e teste é realizado o treino do classificador. Para isto é chamada a função *LR\_coef\_calc* que realiza o processo de otimização matemática através do método da descida do gradiente para adequar o modelo criado a cada movimento minimizando a função custo conforme explicado no Subcapítulo 3.3.3 deste trabalho. A Figura 41 apresenta o decréscimo da função custo após 10 iterações do método e como critério de parada do método foi definido o valor limite de mil iterações.

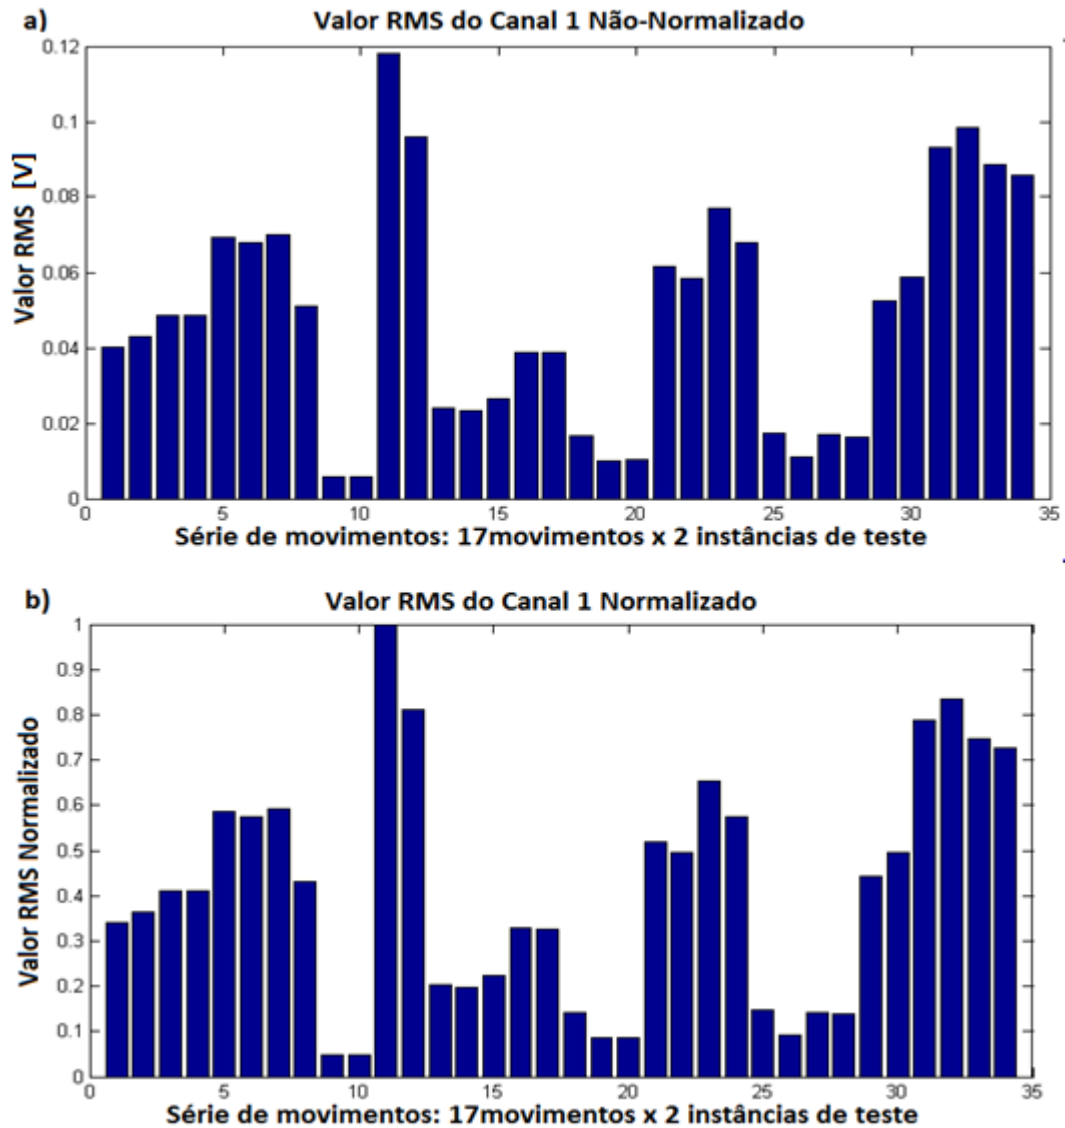


Figura 40 Valores de RMS do canal 1 do voluntário 1 da base NinaPro: a) Não-normalizados e b) normalizados. Os valores apresentados são relativos ao  $k=1$  do  $k$ -fold.

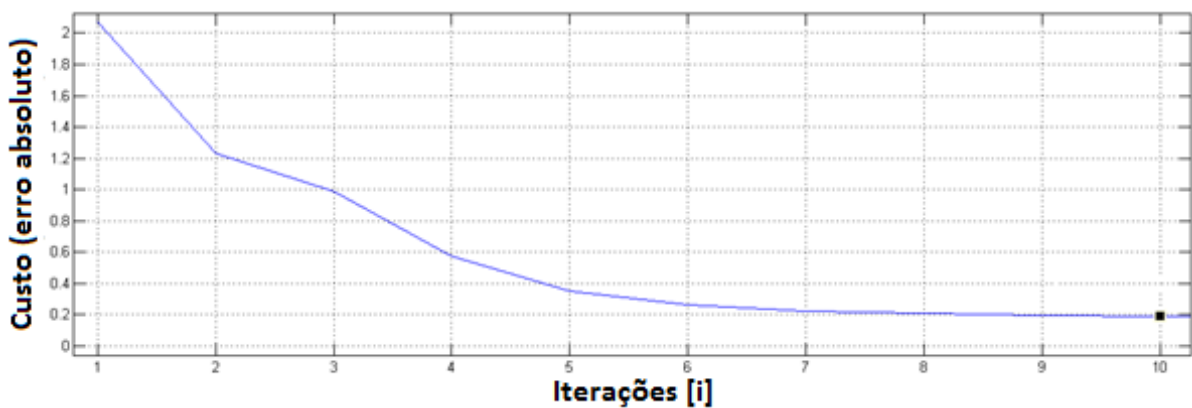


Figura 41 Decréscimo da função custo (erro) do sistema até a décima iteração entre saída prevista e saída testada pelo classificador no processo de otimização matemática.

Para cada movimento de cada voluntário é criado um modelo definido através do processo de otimização matemática. O fluxograma utilizado para a obtenção de cada modelo é apresentado na Figura 42.

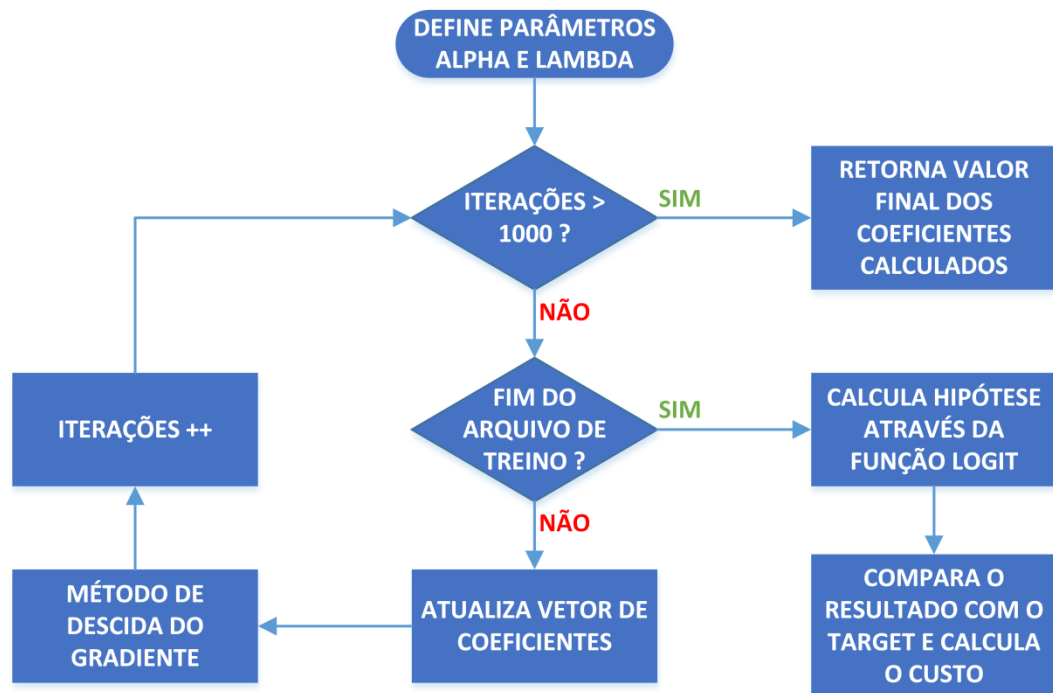


Figura 42 Fluxograma da função LR\_coef\_calc.

Após a obtenção de cada modelo, a função *LR\_result\_calc* calcula a probabilidade de cada instância de teste pertencer a cada classe de movimento. Esta função é utilizada para testar o método gerado, procedimento este, apresentado na Figura 43.

Esta função percorre todos os movimentos a serem classificados e utiliza as características extraídas como parâmetro de entrada para o teste com o modelo gerado para cada movimento. A variável de saída do teste é a probabilidade de que um certo movimento de entrada pertença as classes. Desta forma, cada movimento tem uma probabilidade associada – que varia de 0 a 1 – de pertencer a uma determinada classe. Essa probabilidade é salva e utilizada posteriormente como probabilidade *a posteriori*, para a efetiva classificação dos movimentos. A Figura 44 apresenta um teste realizado para o valor  $k=1$  do *k-fold* realizado.



Figura 43 Fluxograma da função LR\_result\_calc.

Para a Figura 44 foram testadas duas repetições para cada um dos movimentos. O dataset de teste foi organizado de modo a ordenar os movimentos conforme suas classes para melhor visualização dos resultados. Desta forma, os movimentos 1 e 2 pertencem à classe 1, 3 e 4 à classe 2 e assim incrementalmente até 33 e 34, que pertencem à classe 17, que representa o 17º movimento distinto a ser realizado, neste exemplo, o movimento de extensão do pulso.

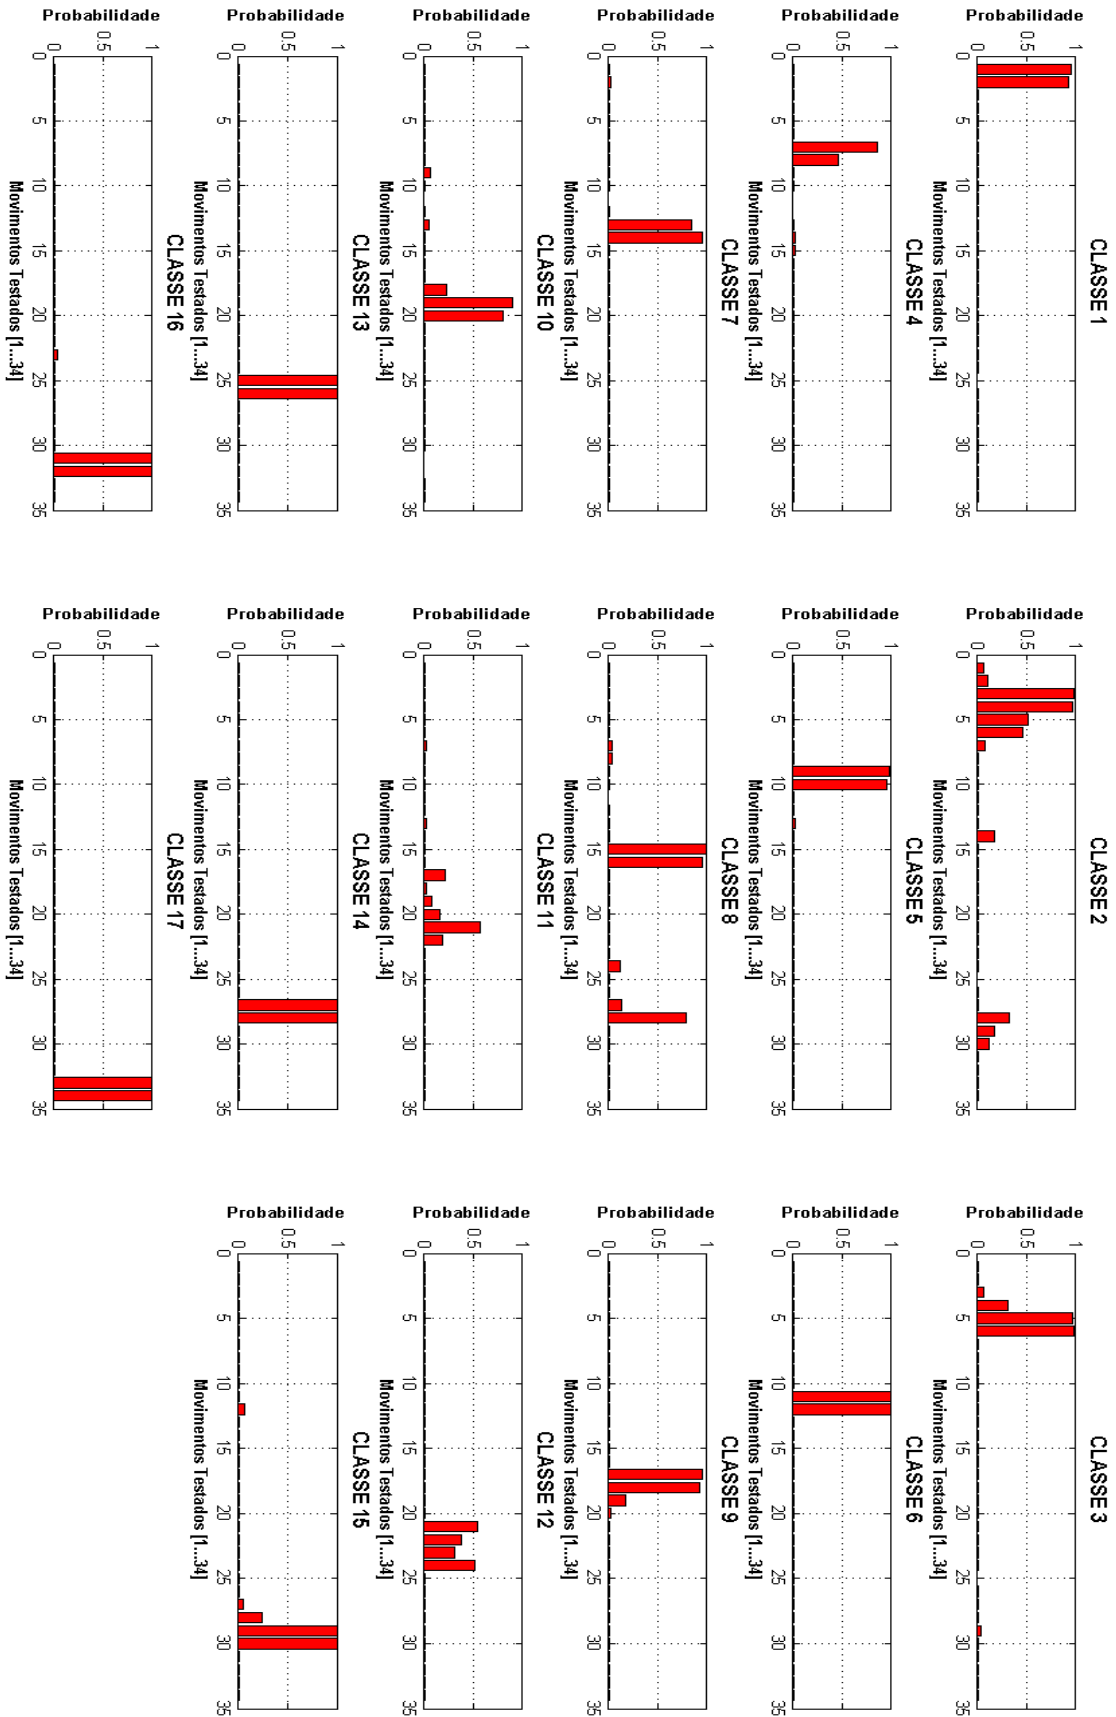



Figura 44 Probabilidades a posteriori calculadas para uma instância do k-fold para o voluntário 1 da base de dados NinaPro.

#### 4.4.2.4 Classificação

Depois de calculadas as probabilidades de um movimento pertencer a cada uma das classes, é realizada a classificação através da heurística *One-Versus-All*. Por este método, as probabilidades de todas as classes são consideradas e a que tem a maior probabilidade é considerada como “classe vencedora” e tem o movimento classificado com o seu rótulo. Como exemplo, é possível visualizar as probabilidades calculadas na Figura 45.



**Figura 45 Probabilidades: colunas em vermelho representado a classe 1 e colunas em laranja representando a classe 2 de movimentos.**

Na representação gráfica da Figura 45 é possível observar as probabilidades calculadas para os primeiros 3 movimentos. Os movimentos foram previamente organizados de forma que os 2 primeiros pertençam à classe 1 e o 3 à classe 2. No gráfico, as colunas vermelhas representam a classe 1, as laranjas a classe 2, e assim sucessivamente, conforme indicado pela legenda. Para este exemplo, é possível observar que as probabilidades dos movimentos 1 e 2 pertencerem a classe 1 e da mesma forma o movimento 3 tem a maior probabilidade ligada à classe 2, acarretando em uma classificação correta dos dados.

Desta forma, sabendo os movimentos que estão sendo testados e sua ordenação na matriz de teste, basta verificar se a maior probabilidade de classificação ocorre na mesma posição do respectivo movimento, o que constitui uma classificação correta. A medida em que o algoritmo vai sendo executado, métricas parciais de acerto global dos 17 movimentos



(em passos de variação do *k-fold*) vão sendo mostradas para o operador de forma a fornecerem uma ideia de desempenho do sistema. A Figura 46 apresenta o fluxograma da função responsável por avaliar as probabilidades, realizar a classificação dos movimentos e contabilizar a taxa de acerto.

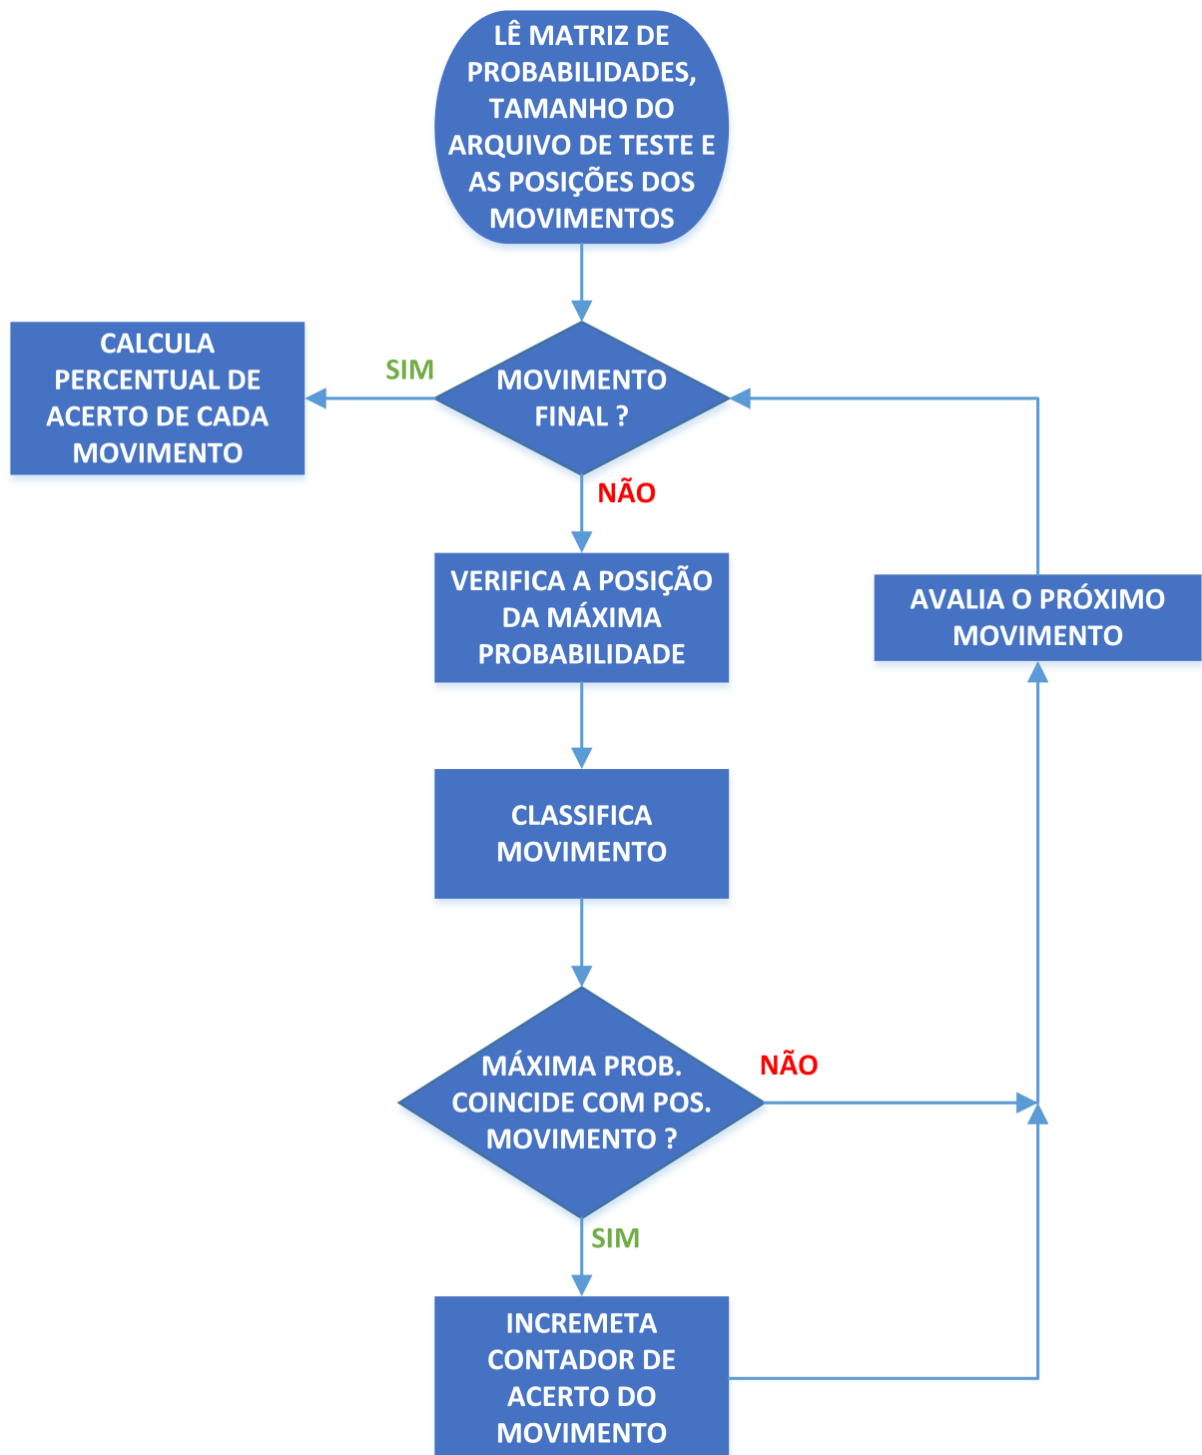


Figura 46 Fluxograma da classificação de movimentos.

#### 4.4.2.5 Tratamento dos dados de saída do sistema

Uma vez obtidos os resultados do sistema, ocorre a chamada de uma função responsável por salvar estes dados. A função salva um arquivo gráfico representando a matriz de confusão gerada pelo Matlab para cada combinação de canais e características testadas. Esta função também gera uma matriz numérica no formato “.mat”, que serve de entrada para uma segunda função responsável por calcular a taxa de acerto individual de cada movimento testado e pela geração de uma matriz com valores adequadamente ordenados para a análise da validação estatística. A Figura 47 apresenta o fluxograma da função que trata os dados de saída do sistema enquanto a Figura 48 apresenta, como exemplo, uma das matrizes de confusão gráficas, que constituem uma das saídas do sistema.



**Figura 47 Fluxograma da função accuracy\_calc.**

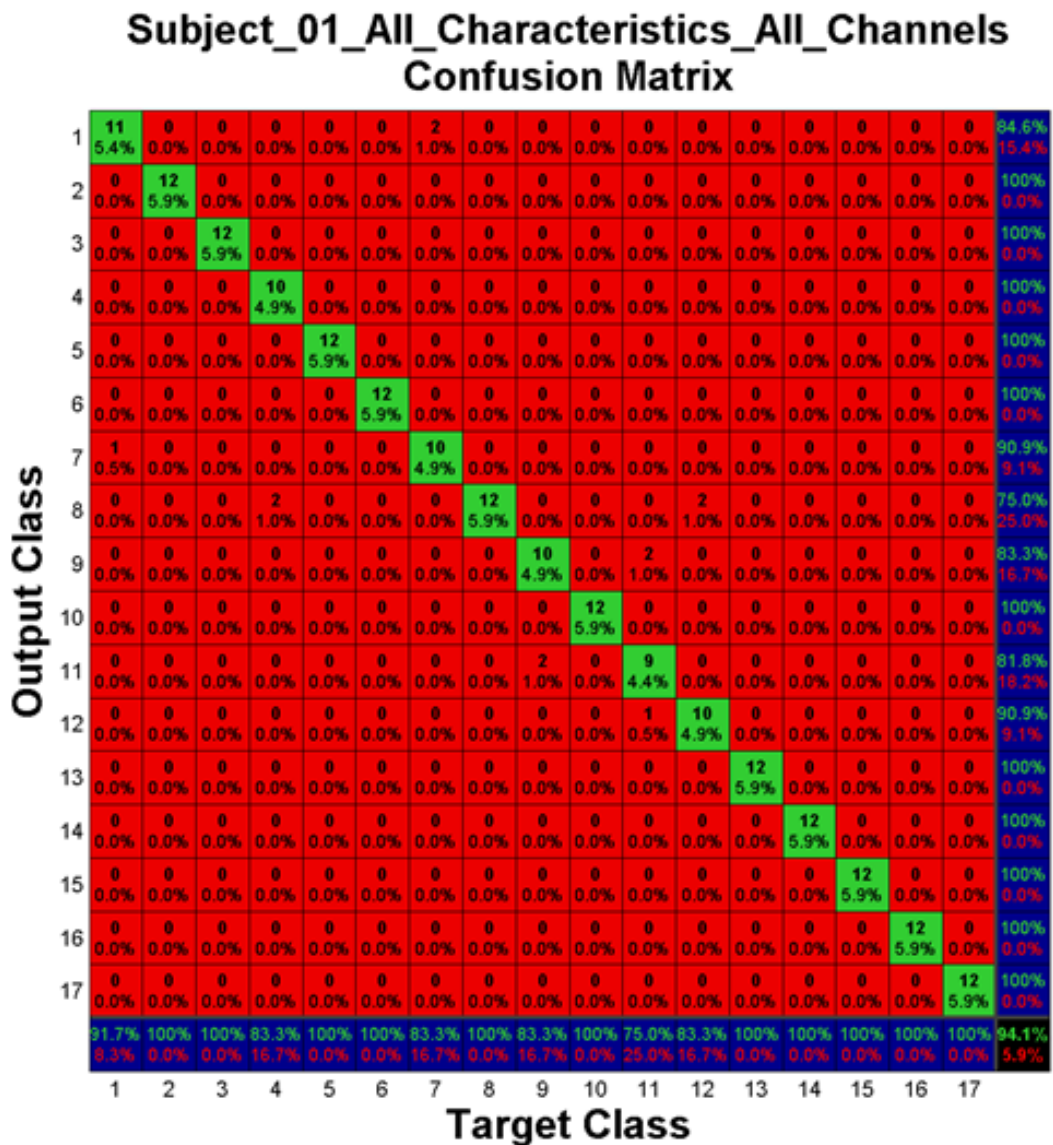
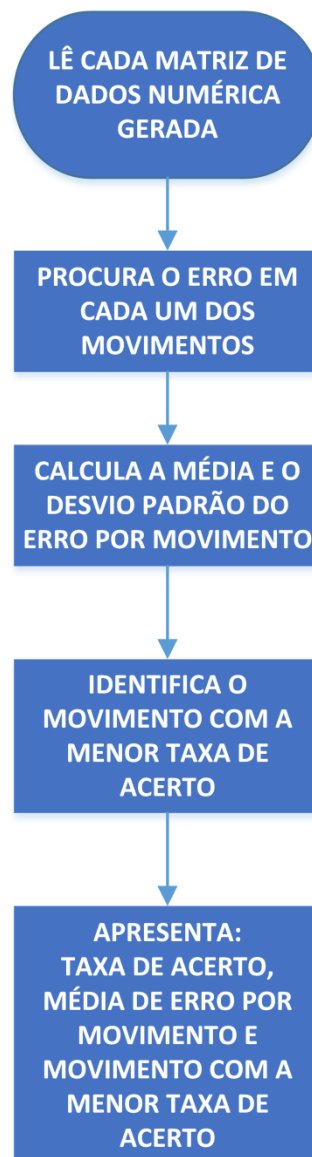


Figura 48 Matriz de confusão gerada pelo sistema para a condição de uso de todos canais e características para o voluntário 1 da base de dados NinaPro não-amputados. Nela é possível visualizar: a taxa de acerto global (fundo preto), a taxa de acerto individual de cada movimento (diagonal principal em fundo verde), as taxas de falso positivo, verdadeiro positivo, falso negativo e verdadeiro negativo (expostos em fundo azul) e quais movimentos foram confundidos em caso de erro (fundo vermelho na mesma coluna do movimento).

Ao utilizar-se das matrizes numéricas geradas pela função anterior, é realizado o cálculo do desempenho do algoritmo em relação à taxa de acerto. Complementarmente à taxa de acerto, é realizado um cálculo para identificar o movimento que possui a maior taxa de erro, o que fornece uma estimativa do quanto a classificação poderia melhorar caso houvesse o descarte deste movimento. A Figura 49 mostra o fluxograma do cálculo das taxas de acerto utilizando as matrizes numéricas geradas.



**Figura 49 Fluxograma da função result\_eval.**

#### **4.4.3 Validação estatística**

Para a validação estatística dos ensaios, foi realizado um Projeto de Experimentos modelo fatorial completo, tendo como variável de resposta a taxa de acerto e como fatores controláveis a variação de características, a variação de canais e os movimentos realizados. É importante ressaltar que não foi possível ter controle sobre a base de dados NinaPro e foi estimado que todas as bases avaliadas seguem as premissas básicas de um Projeto Fatorial

Completo. Porém, mesmo com esta limitação, este é um dos poucos trabalhos, nessa área, a realizar uma avaliação estatística mais robusta de seus ensaios.

A Tabela 8 apresenta a estrutura simplificada do Projeto de Experimentos realizado, onde foram utilizados os valores relativos à média dos seis *k-folds* realizados para cada situação. A Tabela 8 ainda mostra os diferentes níveis utilizados para cada um dos fatores controláveis (17 para movimentos, 11 para canais e 7 para características para cada um dos 50 voluntários utilizados no estudo). O modelo utilizado segue a Equação (34) do Projeto de Experimentos.

$$y_{ijk} = \mu + \alpha_i + \beta_j + \gamma_k + (\alpha\beta)_{ij} + (\alpha\gamma)_{ik} + (\beta\gamma)_{jk} + (\alpha\beta\gamma)_{ijk} + \varepsilon_{ijk} \quad (34)$$

Onde *y* corresponde à resposta de nível *i* na repetição *j*,  $\mu$  corresponde a média geral,  $\alpha$  corresponde ao efeito de cada nível *i* e  $\varepsilon$  ao erro do nível *i* na repetição *j*.

Para maiores detalhes sobre os procedimentos matemáticos utilizados nos cálculos de Projetos de Experimentos recomenda-se a consulta a (MONTGOMERY, 2013 – Capítulos 1 ao 5).

**Tabela 8 Projeto de Experimentos realizado baseado nos resultados de classificação.**

Taxas de Acerto (%)								
<i>i</i> Movimentos ( <i>i</i> = 17 níveis)	<i>j</i> Canais ( <i>j</i> = 11 níveis)							Totais ( $T_{i..}, T_{.j.}$ e $T_{...k}$ )
	1		...			11		
	<i>k</i> Características ( <i>k</i> = 7 níveis)							
	1	...	7	...	1	...	7	
1	$X_{111}$	...	$X_{112}$	...	$X_{1111}$	...	$X_{1117}$	$T_{1..}$
.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.
17	$X_{1711}$	...	$X_{1717}$	...	$X_{17111}$	...	$X_{17117}$	$T_{...}$

Através do Projeto de Experimentos realizado, busca-se fornecer embasamento estatístico às conclusões obtidas neste trabalho. Para tanto, os resultados obtidos da função anterior foram inseridos no programa Minitab 16, onde foram realizadas todas as avaliações

estatísticas. O total de resultados utilizados como parâmetro de entrada para o Projeto de Experimentos realizados é apresentado nas Equação (35) e (36), enquanto o total de resultados processados em todo este trabalho dadas as variações de *k-fold* ( $k=6$ ) é apresentado na Equação (37).

$$Total\ de\ dados = Total_{Movimentos} \times Total_{Variação\ Canais} \times Total_{Variação\ Características} \times Total_{Voluntários} \quad (35)$$

$$Total\ de\ dados = 17 \times 11 \times 7 \times 50 = 65450 \quad (36)$$

$$Total\ de\ dados\ processados = Total\ de\ dados \times k = 65450 \times 6 = 392700\ resultados \quad (37)$$

## 5 RESULTADOS E DISCUSSÕES

Após a devida organização dos resultados e da validação estatística, foi possível averiguar tanto a influência de cada fator escolhido no estudo como a interação entre alguns destes fatores e sua consequência na variável de resposta do sistema, aqui dada pela taxa de acerto (certas vezes referenciada como taxa de acerto global, quando representa a média para mais de um fator). O resultado do Projeto de Experimentos pode ser conferido na Tabela 9.

**Tabela 9 Cálculo do Projeto de Experimentos realizado.**

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade (GDL)	Médias Quadradas	Fator F	P
<b>Movimento (Fator A)</b>	5349194	16	334325	576,42	<b>0,000</b>
<b>Canais (Fator B)</b>	3903054	10	390305	672,93	<b>0,000</b>
<b>Características (Fator C)</b>	24708	6	4118	7,10	<b>0,000</b>
<b>Interação AB</b>	812442	160	5078	8,75	<b>0,000</b>
<b>Interação AC</b>	22128	96	231	0,40	<b>1,000</b>
<b>Interação BC</b>	736318	60	12272	21,16	<b>0,000</b>
<b>Interação ABC</b>	468373	960	488	0,84	<b>1,000</b>
<b>Erro</b>	29908541	64092	467	-	-
<b>Total</b>	48518313	65449	-	-	-

Pelos resultados obtidos, é possível descartar a hipótese nula para todos os fatores e interações ( $P = 0$ ) com exceção da interação dos três fatores e do movimento com as características. A análise a seguir explora mais profundamente os resultados obtidos. As figuras de mérito de avaliação do sistema em relação aos resultados descritos pelas taxas de acerto compreendem:

- taxa de acerto médio global em função de cada movimento realizado;
- taxa de acerto médio global em função de cada combinação de características utilizadas como variáveis de entrada do método de processamento de dados;
- taxa de acerto médio global em função de cada combinação de canais utilizados para a extração das variáveis de entrada;

- efeito da variação dos canais em relação à taxa de acerto por movimentos;
- efeito da variação de características em relação à taxa de acerto por movimentos;
- efeito combinado da variação de canais e características na taxa de acerto médio global.
- a taxa de acerto médio de cada uma das bases de dados utilizada (NinaPro não amputados e amputados e dados adquiridos juntos ao Laboratório IEE);
- taxa de acerto médio para cara voluntário.

O Minitab é atualmente um dos softwares de processamento estatístico mais poderosos e populares utilizados comercialmente na análise de Projeto de Experimentos. Mesmo assim, possui restrições quanto ao nível de combinações internas dos fatores processados (< 2.000 níveis). Devido à impossibilidade quanto ao processamento de dados por restrições de software, os fatores “Voluntários” e “Banco de Dados” foram excluídos do Projeto de Experimentos como fatores controláveis. Ainda assim, é possível realizar alguns cálculos de média a fim de realizar observações interessantes. As análises referentes aos fatores “Voluntários” e “Banco de Dados” encontram-se no Subcapítulo 5.8.

Para facilitar a análise deste capítulo são apresentadas a Tabela 10, que apresenta o número do canal de sEMG utilizado e sua respectiva posição no segmento mão-braço de cada voluntário. Já a Tabela 11 apresenta a relação dos movimentos contemplados neste estudo e a musculatura correspondente envolvida.

**Tabela 10 Posicionamento dos eletrodos utilizados em relação a musculatura.**

CANAL	MÚSCULO
1 ao 8	Distribuídos aleatoriamente entre os músculos: Braquiorradial, Palmar longo, Flexor radial do carpo, Flexor ulnar do carpo, Flexor profundo dos dedos, Flexor superficial dos dedos, Abdutor longo do polegar Pronador redondo.
9	Extensor dos dedos



*Continuação da Tabela 10.*

10	Flexor dos dedos
11	Bíceps braquial
12	Tríceps braquial


**Tabela 11 Principais músculos superficiais do braço e antebraço e suas funções.**

NÚMERO	MOVIMENTO	MÚSCULO
1	Estender o dedo 1	Flexor profundo dos dedos, Flexor superficial dos dedos, Adutor longo do polegar.
2	Estender os dedos 2 e 3, flexionando os demais	Flexor profundo dos dedos, Flexor superficial dos dedos, Extensor dos dedos
3	Estender os dedos 4 e 5, flexionando os demais	Flexor profundo dos dedos, Flexor superficial dos dedos, Extensor dos dedos.
4	Flexionar o dedo 1, estendendo os demais	Extensor dos dedos, Flexor do polegar.
5	Estender todos os dedos	Extensor dos dedos.
6	Flexionar todos os dedos	Flexor profundo dos dedos, Flexor superficial dos dedos.
7	Movimento de apontar	Flexor profundo dos dedos, Flexor superficial dos dedos, Extensor dos dedos.
8	Adução de dedos estendidos	Flexor profundo dos dedos, Flexor superficial dos dedos.
9	Supinar o pulso (dedo 3 como eixo)	Bíceps braquial, Tríceps braquial, Supinador.
10	Pronar o pulso (dedo 3 como eixo)	Bíceps braquial, Tríceps braquial, Pronador redondo.
11	Supinar o pulso (dedo 5 como eixo)	Bíceps braquial, Tríceps braquial, Supinador.
12	Pronar o pulso (dedo 5 como eixo)	Bíceps braquial, Tríceps braquial, Pronador redondo.
13	Flexionar o pulso	Flexor radial do carpo, Flexor ulnar do carpo, Extensor radial longo do carpo.
14	Estender o pulso	Flexor radial do carpo, Flexor ulnar do carpo.
15	Desvio radial do pulso	Extensor longo radial do carpo, Extensor dos dedos.
16	Desvio ulnar do pulso	Extensor ulnar do carpo, Extensor dos dedos.
17	Estender o pulso com a mão fechada	Flexor radial do carpo, Flexor ulnar do carpo, Palmar longo, Flexor profundo dos dedos, Flexor superficial dos dedos.

Fonte: Adaptado livremente de TORTORA, 2007.

### 5.1 TAXA DE ACERTO MÉDIO GLOBAL POR MOVIMENTO

A análise de acerto médio global por movimento permite avaliar, independentemente da variação de canais e características, quais os movimentos que oferecem as melhores taxas de acerto para os procedimentos experimentais utilizados neste trabalho e para as bases de dados utilizadas e para o Projeto de Experimentos realizado. A Figura 50 ilustra os resultados obtidos.



**Figura 50 Taxa de acerto médio global para cada movimento realizado.**

Observando a Figura 50 é possível verificar os movimentos que obtiveram melhor taxa de acerto, são eles: movimento 6 (flexão de todos os dedos), movimento 13 (flexão do pulso), movimento 14 (extensão do pulso), movimento 15 (desvio radial do pulso), movimento 16 (desvio ulnar do pulso) e movimento 17 (extensão do pulso com a mão fechada). Estes movimentos constituem movimentos de maior esforço relativo para o usuário. Além disso, estes movimentos parecem se beneficiar do posicionamento adotado para os eletrodos por dependerem de músculos contemplados tanto no arranjo 1 ao 8, posicionados

em volta da junta radio - umeral, quanto dos canais 9 e 10, posicionados próximo ao punho. A área de posicionamento dos eletrodos 9 e 10 geralmente não possui uma camada adiposa muito espessa e parece permitir que o sinal de sEMG seja adquirido com suficiente qualidade para descrever os movimentos de 13 a 17.

Os movimentos de 8 a 12 possuem pior desempenho, à exceção do movimento 8, o que intuitivamente, já era esperado, à medida que estes movimentos (com exceção do 8) são muito parecidos entre si, o que dificulta a performance do classificador. Também é importante notar a similaridade específica entre os movimentos 9 e 11 e 10 e 12, o que gera mais dificuldade quanto a classificação e também tende a confundir um pouco o voluntário, inserindo erro humano no sistema, algo que foge ao controle e escopo deste trabalho. É interessante observar que dos movimentos de 8 a 12, só o número 8 não oferece dependência direta do bíceps ou tríceps (canais 11 e 12), fato este, que pode indicar um sinal insuficientemente descritivo proveniente destes dois canais. De fato, durante a aquisição de dados do Laboratório IEE foram percebidas algumas dificuldades como mau-contato neste canal específico. Outra hipótese consiste em que a contribuição destes músculos possa ser mais significativa para outros movimentos ou quando exigido o emprego de maior força muscular, o que gera um sinal de maior amplitude. É importante observar também, que esta é uma área que pode concentrar uma camada adiposa que atenua o sinal de EMG a ser captado pelos eletrodos, uma limitação comum quando se trabalha com eletrodos de superfície.

Os movimentos de 1 a 5 constituem movimentos relativos a motricidade fina e são relativamente parecidos entre si, suas taxas de acerto giram em torno da média global de reconhecimento dos movimentos.

O movimento que obteve melhor taxa de acerto médio foi o 13 (flexão do pulso) com 85,3%, enquanto o que teve pior desempenho foi o movimento 11 (supinação do pulso tendo o dedo 5 como eixo) com uma taxa de acerto médio de 54,6%.

Vale ainda ressaltar que os resultados de média global apresentados são compostos por todas as variações de canais, características e voluntários, o que pode esconder alguns pontos importantes como por exemplo a influência dos sujeitos amputados para formação das médias entre os 17 movimentos.

## 5.2 TAXA DE ACERTO MÉDIO GLOBAL EM FUNÇÃO DA VARIAÇÃO DAS CARACTERÍSTICAS

Como no item anterior, a análise de acerto médio global em função da variação das características, possibilita avaliar, independentemente da variação de canais e movimentos, quais características em média ofereceram as melhores taxas de acerto para os procedimentos experimentais utilizados neste trabalho e para as bases de dados utilizadas e para o Projeto de Experimentos realizado. A Figura 51 ilustra a influência da variação das características na taxa de acerto.




Figura 51 Taxa de acerto médio global em função da variação de características.

Ao analisar a Figura 51 é notável que a variação de características não provoca um efeito na média global da taxa de acerto dos movimentos. Por exemplo, em quatro das sete combinações realizadas para as características a taxa de acerto foi de 72%, alterando apenas o algoritmo incerto da análise com três algoritmos significativos, sendo assim, consideradas iguais. O mesmo acontece para outras duas combinações de características (variância e a combinação entre variância e frequência mediana) com taxa de acerto de 71%, diferindo apenas no algoritmo incerto. A menor taxa de acerto foi obtida utilizando-se a característica de RMS isoladamente.


Quanto aos resultados envolvendo as variações das características, convém ressaltar que dependem diretamente da qualidade do sinal, que por sua vez está atrelada ao usuário do sistema. É possível, por exemplo, que um sinal de sEMG de um sujeito amputado seja discrepante a ponto de inviabilizar a utilização de uma característica que forneceu um bom resultado em um classificador utilizado para um sujeito não amputado. De tal forma, as características utilizadas são muito dependentes da etapa de aquisição dos sinais e é válido lembrar que no gráfico da Figura 51 é mostrada a taxa de acerto global e não estão discriminados os desempenhos de cada base de dados. É interessante que alguns estudos abordem algumas características capazes de potencializar dados provenientes de amputados, dados suas limitações como falta de musculatura e tônus muscular por exemplo. Nenhum trabalho com este enfoque foi encontrado na revisão bibliográfica realizada neste trabalho.

Ao mesmo tempo é importante ressaltar que esta análise tratou somente da combinação de três características dentre as muitas - ver Tabela 2 - a serem utilizadas para o processamento de sinais de sEMG. Uma análise abordando mais características seria interessante para confirmar este comportamento observado e testes com o objetivo de reduzir o número de características seriam desejados. A medida em que menos características

utilizadas diminuem o tempo de processamento, tornam o algoritmo computacionalmente mais eficiente, o que é de máximo interesse em aplicações práticas.

### 5.3 TAXA DE ACERTO MÉDIO GLOBAL EM FUNÇÃO DA VARIAÇÃO DOS CANAIS

Outra análise interessante possibilitada por este trabalho consiste em avaliar a influência da variação dos canais na taxa de acerto médio global. Esta análise visa identificar as melhores configurações de eletrodos (canais) em relação às taxas de acerto médio para os casos estudados para os procedimentos experimentais utilizados neste trabalho e para as bases de dados utilizadas e para o Projeto de Experimentos realizado. Os resultados obtidos são apresentados na Figura 52.



**Figura 52** Taxa de acerto médio global em função da variação dos canais.

Como regra geral, é aceito que quanto maior o número de canais utilizados, maior a taxa de acerto obtida porque assim como nas características, o sinal pode ser melhor descrito com mais entradas. Seguindo esta linha de raciocínio, a influência do número de canais

utilizados em tese, deveria ser ainda mais drástica que a do número de características. Essa afirmação se apoia no fato de que as entradas do classificador provêm de  $(N \text{ canais} \times M \text{ características}) + 1$ , portanto, quando se retira um canal, retiram-se três entradas referentes as três características provenientes do sinal daquele canal.

No entanto, através dos resultados obtidos, é perceptível que essa regra não é absoluta, tendo em vista que as melhores médias globais de classificação (81%), diferindo somente no algoritmo incerto, foram obtidas tanto com o uso de todos os canais, quanto na combinação dos canais 1 ao 9 + 12 (10 canais). Ao mesmo tempo a combinação de canais 1 ao 9 + 10 oferece uma taxa de acerto global 10% menor (71%) enquanto a combinação 1 ao 9 + 11 apresenta um desempenho intermediário, com 77%.

Da mesma forma, a pior performance não foi obtida quando somente os canais de 1 a 8 foram utilizados (65%) e sim para a situação na qual foram utilizados os canais de 1 ao 8 acrescidos do canal 10 (59%). Já quando houve a combinação de 1 ao 8 + 12, a taxa de acerto aumentou 9%. Por sua vez, novamente o acréscimo do canal 11 apresenta uma melhora intermediária (62%). Ao invés de constituir a pior escolha em termos de acerto médio, a combinação de canais de 1 ao 8 consiste na quarta pior entre as onze combinações, com taxa de acerto de 65%. Estes resultados deixam claro (assim como demonstrado pelo resultado do Projeto de Experimentos), que os canais influenciam sim na taxa de acerto global dos movimentos realizados. Ainda é perceptível que apesar de haver uma tendência de aumento a medida em que se aumentam os canais, não há uma garantia de que utilizar mais canais ofereça uma melhor taxa de acerto médio. Uma razão para este cenário consiste no posicionamento dos eletrodos e dos movimentos realizados. Como comentado na introdução deste trabalho, é conveniente que os eletrodos estejam posicionados de forma a captarem a maior contribuição possível do músculo responsável por um determinado movimento afim de descrevê-lo. Isto evidencia a dificuldade de se trabalhar com um posicionamento aleatório de

eletrodos e a própria dificuldade de adaptar sistemas para amputados, que nem sempre possuem uma condição muscular adequada.

Ainda em relação ao posicionamento dos eletrodos e aquisição dos sinais, outros fatores que influenciam negativamente a classificação são demonstrados em (CENE *et al.*, 2015; ZHANG & HUANG, 2015). Estes trabalhos mostram como os canais podem às vezes contribuir de forma destrutiva para o processo de treinamento dos algoritmos de classificação. Este tipo de situação decorre da contaminação dos sinais provenientes dos canais predominantemente por ruídos decorrentes de mau-contato e mau-posicionamento dos eletrodos, sendo o mau-contato um fator comumente presente nos ensaios (particularmente nos de longa duração). Este tipo de situação pode ocorrer com mais ênfase em amputados, tendo em vista a frequente falta de tônus muscular adequado para a descrição do movimento através do SME. Esta falta de um sinal de qualidade em razão de falta de musculatura, eletrodos fixados em partes inadequadas dos músculos, eletrodos soltos ou com mau-contato tendem a atrapalhar o treino e/ou o processo de classificação por oferecerem informações não adequadas ou um sinal corrompido. Desta forma, evidencia-se a necessidade de construir métodos computacionais capazes de lidar com este tipo de comportamento, tema este abordado em (CENE *et al.*, 2015; ZHANG & HUANG, 2015).

#### **5.4 TAXA DE ACERTO MÉDIO GLOBAL EM FUNÇÃO DA VARIAÇÃO COMBINADA DE MOVIMENTOS (FATOR CONTROLÁVEL A) E CARACTERÍSTICAS (FATOR CONTROLÁVEL C)**

Após a análise dos fatores isolados, foi realizado um teste de interação entre os fatores. A primeira interação (Fator Controlável A e Fator Controlável C do Projeto de Experimentos) abordada consiste na variação das características e movimentos realizados e seu impacto na taxa de acerto.



Pelo valor de  $p$  (1,00) apresentado para esta interação no Projeto de Experimentos, essa interação entre fatores não é significativa, logo, a análise de interação para estes dois fatores não foi realizada.

### **5.5 TAXA DE ACERTO MÉDIO GLOBAL EM FUNÇÃO DA VARIAÇÃO COMBINADA DE MOVIMENTOS (FATOR CONTROLÁVEL A) E CANAIS (FATOR CONTROLÁVEL C)**

A segunda análise de relação entre fatores controláveis efetuada foi a variação dos canais com os movimentos realizados. Do valor de  $p$  (0,00) obtido para esta interação no Projeto de Experimentos (Tabela 9), conclui-se que os dois fatores interagem significativamente. Através da análise dessa interação, tem-se por objetivo analisar o efeito da variação de canais em cada movimento e se algum deles se mostra absolutamente melhor ou pior que os outros para cada movimento realizado para os casos estudados neste trabalho e para as bases de dados e Projeto de Experimentos realizados. A Figura 53 apresenta a relação dos dois fatores propostos.

Analisando a Figura 53 é possível verificar que algumas combinações de canais utilizados como a do 1 ao 8 + 10 tem desempenho sempre inferiores em relação a outras combinações testadas, por exemplo a que utiliza todos os canais. Estes resultados evidenciam como a escolha dos canais de entrada impacta na taxa de acerto de cada movimento, aqui, discriminando o efeito para cada movimento (na Figura 52 é considerada uma média global entre todos os movimentos). Analisando cuidadosamente a Figura 53 é possível perceber que as taxas de acerto se dividem em dois patamares distintos que não se interceptam entre si. O primeiro grupo, além de ter um desempenho maior, se mostra mais constante nas taxas de acerto. Ainda é interessante notar que no grupo que possui melhor desempenho, o número de canais utilizados varia de dez a doze, evidenciando a tendência a uma maior taxa de acerto quando se utilizam mais canais.

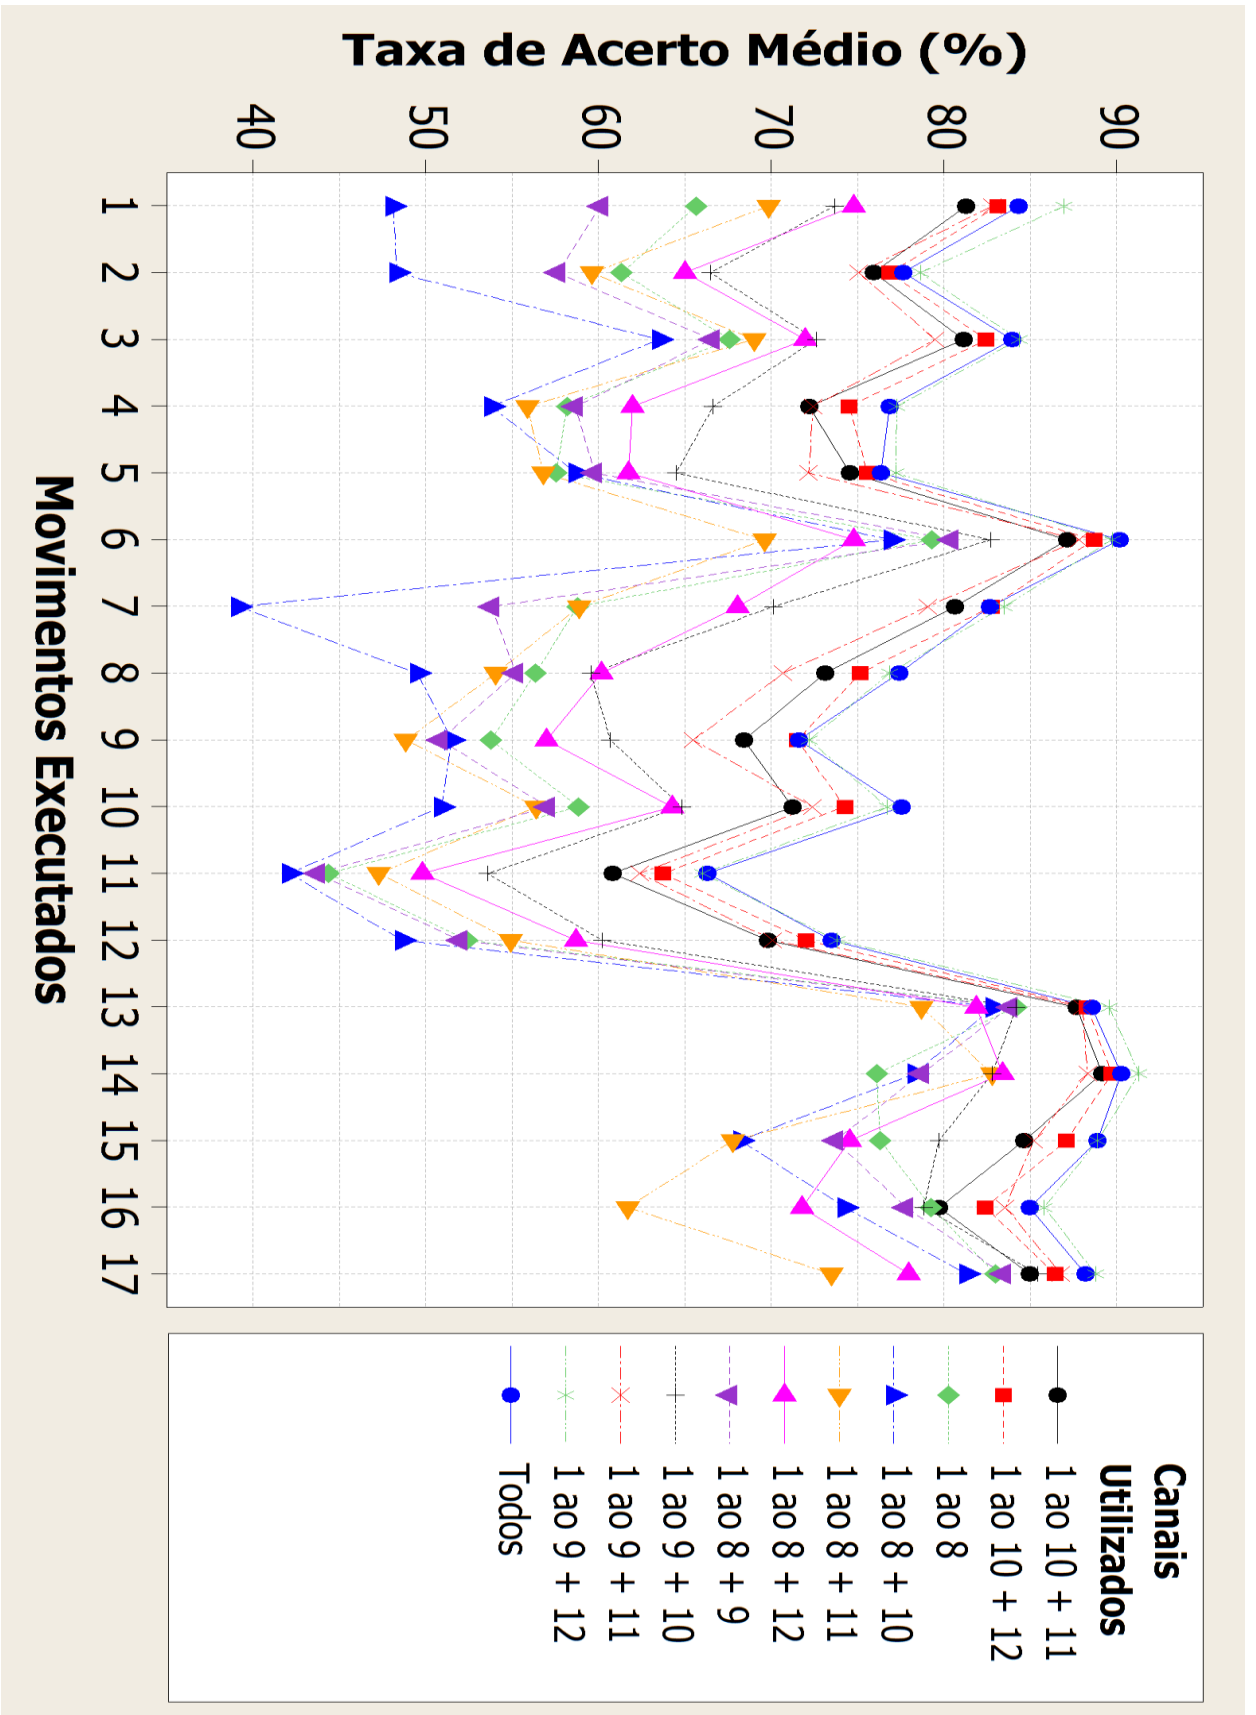


Figura 53 Influência dos canais e movimentos na taxa de acerto médio.

Desta forma fica evidenciada para esta base de dados que não necessariamente a maior quantidade de canais oferece a maior taxa de acerto em média, mas que há uma tendência em obter a maior taxa quando se utiliza um número maior de canais. Entretanto, como já mencionado nos subcapítulos anteriores, fica evidente também que o posicionamento destes canais, e, portanto, a escolha de músculos adequados a serem utilizados para a caracterização dos movimentos é de fundamental importância para uma taxa de acerto satisfatória. Esta afirmação se baseia no fato de combinações com o mesmo número de canais obterem desempenho bastante discrepante, a exemplo a combinação 1 a 9 + 10 e 1 a 9 + 12, que, por exemplo, chegaram a uma diferença de quase 20% na classificação do movimento 8.

#### **5.6 TAXA DE ACERTO MÉDIO GLOBAL EM FUNÇÃO DA VARIAÇÃO COMBINADA DE CARACTERÍSTICAS (FATOR CONTROLÁVEL B) E CANAIS (FATOR CONTROLÁVEL C)**

Esta análise de interação de fatores é realizada com a variação de canais e características, considerando seu impacto na taxa de acerto médio entre todos os movimentos. Do valor de  $p$  (0,00) obtido para esta interação no Projeto de Experimentos (Tabela 9), conclui-se que os fatores B e C interagem significativamente. Através desta análise, se busca identificar as condições mais propícias de variação destes dois fatores para a taxa geral de acerto médio e assim estabelecer um melhor cenário que contemple todos os movimentos realizados. A interação da variação de canais e características é ilustrada na Figura 54.

A Figura 54 é particularmente útil no sentido de considerar a média geral de todos os movimentos e ao mesmo tempo ilustrar o desempenho dos outros dois fatores do experimento, de forma a ilustrar o efeito da variação destes dois fatores na média global de acerto. A Figura 54 mostra uma divisão em dois grupos distintos, assim como ocorria na Figura 53.

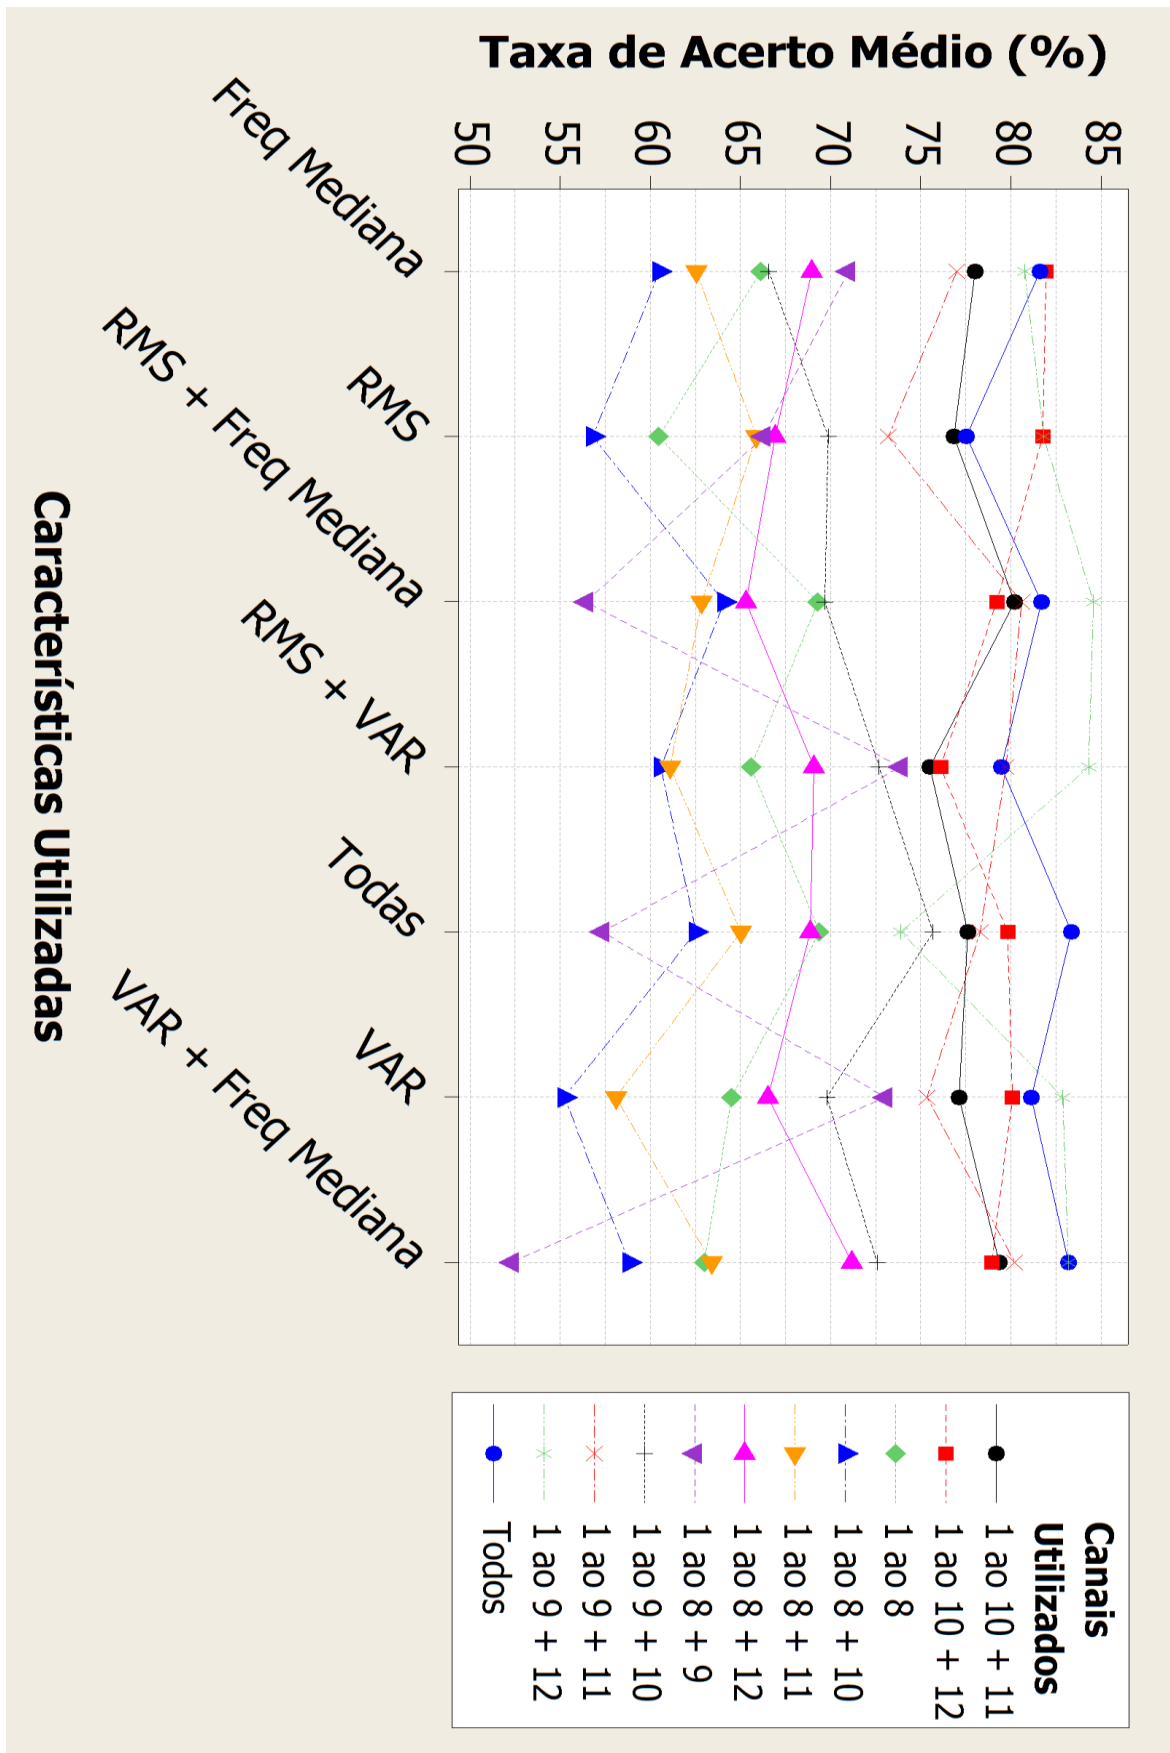


Figura 54 Influência dos canais e características utilizados na taxa de acerto.

É possível observar também o desempenho superior para as combinações de características de RMS + frequência mediana e RMS + variância. Curiosamente para o arranjo de canais mais eficiente (1 ao 9 + 12), o pior desempenho deu-se na utilização de todas as características, evidenciando que mesmo no caso da utilização dos canais mais propícios à classificação, as características utilizadas têm um impacto considerável na taxa de resposta. Isto parece mostrar que a escolha dos canais potencializa o efeito da escolha das características quanto à classificação dos movimentos, o que acontece, por exemplo, no caso dos canais 1 ao 8 + 9, onde se tem uma variação de mais de 20% exclusivamente em função da característica utilizada. Visualmente também é possível notar que um maior número de canais utilizados tende a conduzir não só a uma maior taxa de acerto, mas também a uma menor variação em função das variações das características.

### **5.7 TAXA DE ACERTO MÉDIO GLOBAL EM FUNÇÃO DA VARIAÇÃO COMBINADA DE MOVIMENTOS (FATOR CONTROLÁVEL A), CARACTERÍSTICAS (FATOR CONTROLÁVEL B) E CANAIS (FATOR CONTROLÁVEL C)**

Assim como ocorre no Subcapítulo 5.4, ao conferir o valor de  $p$  (1,00) na Tabela 9, verifica-se que as interações entre os fatores A, B e C para os casos estudados neste trabalho e para as bases de dados e Projeto de Experimentos, não é significativa. Logo, a análise de interação para estes fatores não foi realizada.

### **5.8 TAXA DE ACERTO MÉDIO POR BASES DE DADOS E ENTRE VOLUNTÁRIOS**

Este subcapítulo é dedicado às análises referentes aos fatores “Voluntários” e “Banco de Dados”, que foram descartados como fatores controláveis na análise anterior por uma limitação de software. O ideal seria realizar um Projeto de Experimentos com os cinco fatores controláveis possíveis para o banco de dados total formado (Base de Dados, Voluntários,


Canais, Características e Movimentos). Desta forma seria possível diferenciar e analisar também a contribuição de cada voluntário e base de dados. Realizando isto, este trabalho apresentaria uma análise de dados extremamente robusta e que não é efetuada na grande maioria dos trabalhos desta área. Mesmo a análise aqui apresentada com suas limitações (1 repetição, dificuldade de garantir a aleatoriedade, desconsideração de “Voluntários” e “Base de Dados” como fatores controláveis) é de interesse geral para a área e apresenta uma análise estatística dificilmente encontrada em outros trabalhos da área.

Analisando a Figura 55 podem-se observar dois pontos interessantes: (1) Como esperado, a média de acertos para os voluntários amputados é menor do que as duas bases de dados de voluntários não amputados utilizadas (NinaPro e IEE). Como já citado nos subcapítulos anteriores, a classificação de sinais provenientes de sujeitos amputados é dificultada principalmente por fatores como a falta de musculatura e a falta de tônus muscular, o que tende a alterar o sinal, afeta as características extraídas e geralmente diminui o desempenho do classificador. (2) A média global da taxa de acerto das duas bases de dados de não amputados é igual. Numericamente diferia por uma ordem de  $10^{-3}$ , mas considerando que os cálculos realizados se baseiam em médias sucessivas referentes aos acertos dos movimentos, características, canais e voluntários, essa diferença se torna desprezível. Esse resultado, demonstra que um dos objetivos secundários do trabalho que era o de iniciar a geração de uma base de dados compatível com o padrão NinaPro foi satisfeita.

Além das médias por grupo, também foi calculado o valor médio de taxa de acerto global para cada voluntário em cada base. As Figuras 57, 58 e 59 apresentam os resultados obtidos para as bases NinaPro Não Amputados, IEE e NinaPro Amputados, respectivamente.


As Figuras 55 a 58 evidenciam algo que o voluntário é o principal fator e maior complicador do sistema. Apesar dos dados receberem o mesmo tratamento e as características utilizadas e os canais serem os mesmos, os resultados são bastante discrepantes. Esta

diferença não ocorre somente entre amputados e não amputados, mas também entre sujeitos da mesma base.



**Figura 55** Comparação entre as bases de dados utilizadas neste estudo.

Tal diferença encontrada já era esperada, pois se o voluntário é o gerador de sinais do sistema, pessoas diferentes geram sinais diferentes em função de alguns fatores já explicitados na introdução deste trabalho como quantidade de tecido adiposo, musculatura, contato dos eletrodos, entre outros. Há ainda uma série de outros fatores importantes a serem considerados como a força com a qual o movimento foi realizado, cenários de fadiga muscular, execuções erradas dos movimentos e o treinamento ou experiência que os sujeitos envolvidos já tenham com este tipo de interface. Há diversos estudos – a exemplo (LOCK, 2005; JIANG, 2014) – demonstrando correlações significativas entre o treinamento e a taxa de acerto. Existem, inclusive, discussões a respeito do quão eficiente deve ser o classificador e do quanto deve ser exigido do sujeito para que se adapte ao sistema.




**Figura 56** Taxas de acerto global para os voluntários da base NinaPro Não Amputados.

Como as bases de dados dos não amputados IEE e NinaPro tem tamanhos diferentes, afirmar que a taxa de acerto se manteria igual à medida em que a base IEE crescesse não seria adequado. Ao mesmo tempo convém observar que a base do IEE poderia inclusive superar a base NinaPro em taxa média de acertos pois a menor taxa da base IEE (voluntário 41) é mais alta do que as quatro menores da base NinaPro (voluntários 8, 14, 16 e 18), evidenciando a qualidade, no mínimo compatível, dos sinais adquiridos.

A base NinaPro disponibiliza uma tabela com a descrição dos voluntário e algumas características importantes como anos desde a amputação, grau da amputação, se o voluntário usa próteses, qual tipo de prótese e outras informações relevantes. A classificação de dados de SEMG provenientes de amputados merece atenção especial, na medida em que estes são os sujeitos-alvo mais importantes do estudo e que em um cenário de aplicação experimental, serão os usuários do sistema desenvolvido. Surpreendentemente os voluntários 38 e 39, membros desta base, obtiveram resultados que figuram dentro dos 15 melhores resultados



obtidos dentre todos voluntários. Ao mesmo tempo esta base também apresenta o caso de menor taxa de acerto (voluntário 34).



**Figura 57** Taxas de acerto global para os voluntários da base IEE.

O desempenho do voluntário 38 provavelmente está relacionado ao seu baixo grau de amputação (10% do antebraço, há 14 anos) e ao fato dele já utilizar uma prótese com controle mioelétrico (não é relatado há quanto tempo). O voluntário 39 possui 50% de amputação do antebraço há dois anos e também utiliza uma prótese por controle mioelétrico. Já o voluntário 34 também é reportado como tendo um baixo grau de amputação (10% do antebraço), mas como utilizador de prótese estática.

É importante ressaltar que para adequar-se a estas próteses de controle mioelétrico, o paciente geralmente passa por um considerável período de fisioterapia e mais um período de adequação à prótese. O que possibilita manter a musculatura ativa o suficiente para receber e utilizar este tipo de equipamento. Estes resultados também evidenciam a importância e eficácia do treinamento para o controle deste tipo de prótese. Como regra geral, o usuário

aprende a interagir com a prótese utilizando ela como um equipamento qualquer do dia a dia. Exposto isso, fica evidente que embora um classificador bem ajustado ao modelo seja essencial no processo de classificação do sinal, um operador experiente é possivelmente, tão importante quanto.




Figura 58 Taxas de acerto global para os voluntários da base NinaPro Amputados.

## 5.9 MELHORES MÉDIAS DE RESULTADOS

As análises realizadas se basearam na média dos valores obtidos dentre todas as variações contempladas neste trabalho. Apesar deste valor médio ser uma boa figura de mérito do desempenho do método implementado, é notável que diversas condições abordadas quanto a variações de características, canais e voluntários prejudicam a taxa de acerto e impedindo a conferência da capacidade a ser alcançada nas melhores condições. Em função disto, este subcapítulo demonstra os resultados obtidos considerando as médias dos melhores cenários calculados para cada movimento. Para a obtenção destes valores foi considerado somente o melhor resultado obtido entre todas as variações de canais e características para

cada voluntário. As médias apresentadas na Tabela 12 foram calculadas considerando o número de voluntários de cada base.

**Tabela 12 Melhores médias para cada movimento.**

Taxa de Acerto (%)									
Movimento	Não Amp.	Amp.	IEE	Média	Movimento	Não Amp.	Amp.	IEE	Média
1	97,2	92,5	96,7	95,5	10	97,5	85,0	87,6	90,0
2	95,1	88,4	93,4	92,3	11	87,8	84,2	84,1	85,4
3	96,2	87,5	100	94,6	12	93,7	82,5	94,9	90,4
4	92,2	94,3	94,2	93,6	13	98,6	80,8	99,2	92,9
5	90,3	85,1	100	91,8	14	99,7	88,3	99,2	95,7
6	99,2	92,6	91,7	94,5	15	96,2	94,2	98,3	96,2
7	96,1	83,2	93,3	90,9	16	96,1	85,8	99,2	93,7
8	94,5	90,9	95	93,5	17	100	87,5	92,5	93,3
9	92,3	77,5	94,9	88,2					

Analisando os resultados médios obtidos para cada movimento é possível conferir o alcance da técnica nesta aplicação. Com exceção dos movimentos 9 e 11, todos os movimentos atingiram uma média maior ou igual a 90%. De fato, a Tabela 13 demonstra as médias por bases e confirma o bom desempenho e a aplicabilidade da técnica mesmo para o grupo de voluntários amputados.

**Tabela 13 Médias gerais por base nos melhores casos.**

Não Amp.	Amp.	IEE	Média
95,5	87,1	95,0	92,5

## 5.10 COMPARAÇÃO DOS RESULTADOS COM TRABALHOS RELACIONADOS DA ÁREA

A Tabela 12 apresenta a comparação com alguns trabalhos relacionados na área em função das suas respectivas taxas de acerto global. A comparação quantitativa entre trabalhos nesta área é um tema complicado pelo fato de quase sempre as metodologias utilizadas divergirem na aquisição, no número e tipo de movimentos realizados, nas características

extraídas do sinal e nos classificadores utilizados. A Tabela 12 tem por objetivo reunir de forma concisa algumas destas metodologias utilizadas e compará-las a este trabalho.

**Tabela 14 Trabalhos Relacionados na área de processamento de sEMG**

Autor	Classificador	Características	Movimentos	Número de Voluntários	Taxa de Acerto (%)
<b>HAN &amp; JO, 2014</b>	Modelo Hierárquico Bayesiano	Valor Médio Absoluto	8	7	77% - 84%
<b>KHEZRI &amp; JAHED, 2007</b>	<i>Adaptive Neuro-Fuzzy Inference System</i> (ANFIS)	Características no Tempo, Frequência e um Modelo Híbrido Tempo-Frequência	8	4	78% - 83%
<b>LOCK, 2005</b>	LDA, ANN and GMM	Estatísticas de Hudgins no Tempo, Características Autoregressivas e Combinação de Ambas	6 (Modelo Virtual)	12	~70% - ~100%
<b>RAJESH &amp; KUMAR, 2009</b>	<i>k-Nearest Neighbors</i> (kNN)	RMS Entropia Desvio Padrão	6	20	83,3% 96,6% 91,6%
<b>FAVIEIRO, 2012</b>	Neuro-Fuzzy	RMS	11	7	65%
<b>NILSON, 2014</b>	SVM	RMS, Média, Variância, Desvio Padrão, <i>Skewness</i> , <i>Kurtosis</i> (algumas combinações)	9	3	91,3%
<b>GIJSBERTS, 2014</b>	Classificador Multimodal para Dados de EMG e Acelerometria	RMS, Histograma do sEMG, <i>Marginal Discrete Wavelet Transform</i> , 3 características	40 Movimentos descritos em (GIJSBERTS, 2014)	40 (Não-Amputados)	73,6% 75,9% 77% 77,8%
<b>LOPES, 2014</b>	LR	RMS, Desvio Padrão, Variância e <i>Skewness</i>	9	5	95,1% (melhores casos)
<b>Este Trabalho</b>	<b>LR</b>	RMS, Variância e Fequência Mediana (Todas as combinações possíveis)	17 movimentos apresentados	50: 40 Não-Amputados, 10 Amputados	74,2% 61,9%

(HAN & JO, 2014) utilizam uma característica de entrada em um classificador hierárquico bayesiano para classificar sete movimentos (Flexão e Extensão do Pulso, Desvio

Ulnar e Radial do Punho, Pronação e Supinação do Antebraço, Fechamento e Abertura da Mão). Seis destes oito movimentos são contemplados (entre outros) neste trabalho, sendo descritos pelos movimentos de número 13, 14, 16, 15, 6 e 5, respectivamente. Os movimentos de pronação e supinação do antebraço diferem pelo fato de serem realizados com a mão fechada por (HAN & JO, 2014). Calculando uma média dos movimentos 5, 6, 13, 14, 15 e 16 deste trabalho chega-se a uma taxa de acerto média global de 79,5%, o que fornece uma taxa compatível com (HAN & JO, 2014) que por sua parte levam vantagem em relação ao esforço computacional empregado, tendo em vista que utilizam 4 canais e apenas uma característica.

Já (KHEZRI & JAHED, 2007) utilizam ANFIS aliadas a 4 pacotes de características que sofrem redução de dimensionalidade antes de serem utilizadas pelo classificador para a classificação de 8 movimentos (Flexão e Extensão do Pulso, Desvio Ulnar e Radial do Punho, Movimento de pinça, Flexão do dedão com os outros dedos esticados, Fechamento e Abertura da Mão). Desta forma são utilizados os mesmo seis movimentos que este trabalho possuía em comum com (HAN & JO, 2014) acrescidos do movimento número 4 desta base (o movimento de pinça não consta nesta base). Considerando os movimentos descritos, este trabalho apresenta uma média de 77,6%, o que se aproxima do valor médio de 80,5% apresentados por (KHEZRI & JAHED, 2007).

O trabalho de (RAJESH & KUMAR, 2009) apresentam a classificação de 6 movimentos (os mesmos descritos em (KHEZRI & JAHED, 2007) desconsiderando os movimentos de Desvio Ulnar e Radial de Punho). Em seu trabalho, RAJESH & KUMAR (2009) utilizam as características de RMS, Desvio Padrão e Entropia adquiridas de 20 sujeitos em um classificador baseado em kNN. Sua taxa de acerto perfaz 83,3%, 91,6% e 96,6%, respectivamente. Calculando a média dos movimentos similares - movimentos 1, 5, 6, 13 e 14 - utilizados neste estudo chega-se ao valor de 78,6%. Em comparação com este estudo especificamente, obteve-se uma taxa de acerto consideravelmente menor que o melhor

resultado relatado (96,6%), porém é muito importante ressaltar que todos os trabalhos aqui relatados na comparação com exceção de (GIJSBERTS, 2014), um número consideravelmente menor de voluntários foi utilizado e ao mesmo tempo utilizam-se dados provenientes de voluntários não amputados, o que eleva (potencialmente) em muito o resultado da taxa de acerto médio. Uma avaliação mais correta seria possível ao realizar-se em Projeto de Experimentos com o fator controlável voluntário, que em tese, deixaria esta constatação bastante evidente. Outro fato importante é que com exceção do trabalho de (GIJSBERTS, 2014), que segue o mesmo posicionamento de eletrodos deste trabalho, os demais utilizam a abordagem de posicionamento específico, de acordo com os movimentos alvos da classificação.

O trabalho apresentado por (LOCK *et al.*, 2005) utiliza a série de características descritas para a caracterização *online* de 6 movimentos em um ambiente virtual. Este trabalho relata taxas de acerto que variam entre 70% e 100%. O trabalho de LOCK *et al.*, (2005) possui somente 4 movimentos similares aos realizados neste trabalho (5, 6, 9 e 10). Calculando a média para estes movimentos chega-se ao valor de 69%, resultado compatível com o relatado. No entanto, a principal contribuição de (Lock *et al.*, 2005), consistiu em questionar, mesmo a 20 anos atrás, a correlação entre o tempo de execução do movimento e a adequação do usuário a este tipo de controle. Em 2014, (JIANG *et al.*, 2014), questionam a importância efetiva do desempenho do classificador em relação ao aprendizado do usuário na utilização do sistema e apresentam em seu estudo resultados de classificação *offline* e *online* para três classificadores (Regressão Linear, kNN e SVM). Partindo dos resultados *offline* e tendo valores consistentemente diferentes, (JIANG *et al.*, 2014) comprovam (é realizada uma validação estatística) que na classificação online os resultados são praticamente equivalentes, mesmo comparando o classificador de pior desempenho com o melhor. Considerando estes resultados, este é um aspecto que definitivamente merece ser estudado em trabalhos futuros.

Em seu trabalho, (FAVIEIRO, 2012) utiliza *Neuro-Fuzzy* a partir de um sinal segmentado *online* de 7 voluntários para a classificação de 11 movimentos distintos do segmento mão-braço, obtendo uma taxa global de acertos de 65%. Dos 11 movimentos abordados naquele trabalho, três (movimento 6, 13 e 14) são similares aos movimentos abordados neste trabalho, o que não oferece uma análise quantitativa muito adequada na comparação entre os trabalhos. Ao se considerar a média para estes três movimentos, chega-se ao valor de 84%. Entretanto, a principal contribuição de (FAVIEIRO, 2012) se dá pelo fato de aquele trabalho abordar movimentos compostos, que lidam com mais de um grau de liberdade e que são mais dificilmente classificados. Além disso, foi explorada a segmentação online dos dados, o que tende a gerar taxas de acerto mais baixas em cenários não ideais de segmentação.

O trabalho de (NILSON, 2014) é similar ao de (FAVIEIRO, 2012). Nele são explorados 9 dos 11 movimentos anteriores através da extração *offline* de seis características as quais serviram para fazer uma variação de dados de treinamento do classificador, sempre com o valor mínimo de cinco características. Outra abordagem interessante do trabalho de (NILSON, 2014) consiste na variação dos canais utilizados para a classificação do sinal de EMG, embora feito com poucos (3) voluntários, o trabalho possui sete níveis de repetição. O que confere certa confiabilidade à taxa média de acerto de 91,3% encontrada.

Em termos de Regressão logística, (LOPES, 2014) apresenta os mesmos sinais de (NILSON, 2014) e utiliza 4 características e 8 canais e a variação entre estes fatores para efetuar a sua análise de taxa de acerto que é relatada como 95,1% para os melhores casos (resultado compatível com este trabalho). Um aspecto interessante do trabalho de LOPES (2014), além do fato da variação de características e canais utilizados para a classificação é a abordagem utilizada no processo de otimização, que consiste em L-BFGS (*Limited-memoryBroyden-Fletcher-Goldfarb-Shanno*), um algoritmo computacionalmente mais

eficiente - respeitada as suas restrições como a convexidade da função a ser otimizada - que a descida do gradiente, utilizada neste trabalho.

Finalmente, em (GIJSBERTS, 2014) é abordada a base de dados NinaPro. Seu trabalho possui 40 movimentos por abordar as 3 subclasses de não-amputados que perfazem o pacote NinaPro para a classificação realizada a partir de 3 características e da combinação entre elas com 3 diferentes *kernel*s do classificador. Já este trabalho, se utiliza apenas da segunda subclasse, que contém 17 movimentos (focados no segmento mão-punho) para amputados e não-amputados do pacote NinaPro. No trabalho de (GIJSBERTS, 2014) é explorada e enfatizada a contribuição dos dados de acelerometria, também componentes da base NinaPro. De fato, é mostrado que a taxa de acerto aumenta em até 9% quando estes dados são utilizados em conjunto com os dados de sEMG.



## 6 CONCLUSÕES

O trabalho proposto tinha como objetivo elaborar um algoritmo de inteligência computacional baseada em regressão logística para a classificação de movimentos do segmento mão-braço através do processamento de sinais mioelétricos. Complementarmente pretendia-se iniciar a elaboração de uma base de dados do laboratório IEE, compatível com o padrão NinaPro (em relação a aquisição dos dados e a taxa de acerto obtida). Pretendia-se também efetuar avaliações sobre o impacto da variação de canais e características na taxa de acerto de classificação dos 17 movimentos propostos e no geral.

Para tanto foram utilizadas três bases de dados NinaPro não amputados (30 voluntários), NinaPro amputados (10 voluntários) e IEE (10 voluntários) que perfazem uma base total de 50 voluntários. Toda a parte de aquisição e condicionamento de sinal foi realizada para a base IEE, a base NinaPro já é disponibilizada digitalmente.

O método de segmentação dos sinais foi baseado em *timestamp*, obtido simultaneamente à aquisição de cada sinal. O método de regressão logística foi realizado sobre uma heurística de otimização matemática baseada em descida do gradiente e a classificação realizada considerando a probabilidade *a posteriori* de cada entrada pertencer a cada classe.

As variações de características e canais foram realizadas para o treino e classificação de todos os movimentos realizados por todos os sujeitos. Desta forma, era esperado estabelecer relações de equivalência entre a complexidade computacional empregada e as taxas de acerto resultantes para cada movimento e para a média global de todos os movimentos realizados. Outra análise pertinente possibilitada pela variação de canais incide sobre a influência do posicionamento dos eletrodos na taxa de acerto. A variação de movimentos busca verificar o desempenho entre todos os movimentos considerados,

buscando estabelecer a viabilidade do emprego experimental do método para uso no dia a dia, fornecendo uma métrica de quais movimentos são classificados corretamente com maior frequência, possibilitando a utilização experimental do sistema.

Como evidenciado no Subcapítulo 5.9, o método de inteligência computacional desenvolvido apresentou resultados coerentes com a literatura de referência e por isso pode ser classificado como adequado para este tipo de processamento de sinais. A elaboração de um banco de dados do laboratório IEE foi iniciada e já demonstra bons resultados quanto as taxas de acerto obtidas. Esta base deve seguir em expansão e ser novamente comparada com a base NinaPro para conferência de desempenho em igual número de voluntários e com repetições. Ao mesmo tempo a base deve também ser enriquecida com dados de voluntários amputados.

Quanto ao pré-processamento, a principal crítica é focada em torno do método de segmentação, que foi obtido por *timestamp* e dessa forma, fornece um cenário mais próximo ao ideal. Em uma aplicação experimental para controle efetivo de próteses ou outros dispositivos um método de segmentação *online* precisa ser explorado de forma a permitir a classificação em tempo real (ou o mais próximo disso, considerando o *delay* inserido pelo próprio método) antes de ser realizado por completo, pois de nada serve descobrir qual sinal foi realizado depois de ele já ter acontecido.

Já na etapa de processamento foram realizados alguns testes em uma faixa de valores escolhida com base em testes prévios para o *tunning* do modelo. Estes parâmetros se mostraram bem críticos quanto a classificação obtida como mostra a Figura 34. Estes parâmetros constituem uma etapa importante da realização do método de regressão logística regularizada e não devem ser escolhidos a esmo. Ainda no processamento, o algoritmo de otimização matemática utilizado foi a descida do gradiente por sua simplicidade e garantia de convergência quanto ao mínimo atingido, mas é importante ressaltar os contras deste método,

como o tempo de convergência, quando comparado a outros métodos mais modernos como o L-BFGS, por exemplo. Neste sentido é válida a exploração de outros métodos computacionais (L-BFGS, Newton, Quasi-Newton, etc..), para análise de desempenho. Outro fator a ser melhorado é o critério de parada (definido baseado em testes preliminares como 1000 iterações) que pode ser ajustado com uma estratégia mais inteligente, melhorando a atual convergência em velocidade e possivelmente em precisão também.

Os canais se mostraram bastante críticos quanto a classificação dos movimentos. Apesar da tendência esperada da proporcionalidade entre canais e taxa de acerto, foi evidenciado que a maior quantidade de canais, ao menos para estes movimentos, não assegura a melhor taxa de acerto, o que pode ser explicado por fatores como ruído ou mau-contato dos eletrodos ou a influência dos grupos musculares na realização dos movimentos de interesse.

Sobre os movimentos testados, foram evidenciados desempenhos bastante distintos entre as classes. Desta forma, foi possível averiguar os movimentos que possuem a maior taxa de acerto e que poderiam ser selecionados, caso exista o interesse em desenvolver um sistema portátil, que reduzisse o número de movimentos disponíveis em troca de oferecer uma maior taxa de acerto da intenção do usuário do sistema.

Sobre os resultados de variações de características e canais foi possível observar que apesar de existir uma tendência de proporcionalidade em relação ao número de canais e a taxa de acerto, não há a garantia de que o maior número de canais oferecerá a mais alta taxa de acertos na classificação. Por outro lado, a importância do posicionamento dos eletrodos foi confirmada a medida que sinais mais descritivos geralmente se valem de menos dados, com maior significância para caracterizar mais apropriadamente o sinal. Como demonstrado em trabalhos da área (aqui representados por (CENE, 2015; ZHANG, 2015)) sinais incapazes de descrever o sinal apropriadamente tendem a contribuir negativamente para o desempenho do classificador. Outra conclusão interessante é que apesar das características não se

apresentarem como fator significativo em uma análise geral do Projeto de Experimentos (não apresentarem um valor médio significativamente diferente entre si), elas podem exercer grande influência dentro de um grupo específico de canais utilizados. Isso também demonstra a necessidade de realizar maiores testes com mais características a fim de se chegar em uma generalização.

As médias de acerto entre os grupos foram diferentes como esperado, com os amputados tendo a taxa de acerto mais baixa no geral. Entretanto, as taxas de acerto de alguns amputados que já estão acostumados com o uso de próteses de controle mioelétrico figuraram entre alguns dos melhores desempenhos individuais, indicando a importância do treino com o sistema e do acompanhamento fisioterápico adequado neste processo. Estes números mostram a importância da fisioterapia e acompanhamento dos pacientes em um cenário pós-operatório para que eles possam utilizar este tipo de prótese e usufruir de uma reinserção e vivência mais plena em sociedade.

Todas as conclusões foram fundamentadas em uma análise estatística apropriada (com as limitações em relação aos fatores de “Voluntários” e “Banco de Dados”), considerando os fatores mencionados como variáveis controláveis do Projeto de Experimentos realizado.

## 7 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Existem algumas abordagens que seriam muito interessantes tanto para enriquecer a base de dados adquirida e o método desenvolvido e para consolidar o conhecimento na área.

- Com relação a base de dados, seria interessante conseguir sujeitos amputados que pudessem enriquecer a base IEE e assim permitir comparações com os sujeitos amputados da base NinaPro. A aquisição dos dados seria facilitada caso os eletrodos fossem ativos e sem fio, o que melhoraria o conforto do voluntário durante o ensaio e catalisaria o processo de aquisição, uma vez que não seria mais necessária a montagem de todos os cabos e conexões do sistema e ele seria simplificado.
- Em relação ao método, a primeira mudança indicada seria sobre o método de segmentação, tendo em vista que se visa sempre uma aplicação prática e um método *offline*, como o utilizado no caso deste trabalho inviabilizaria a aplicação. Como mencionado no capítulo anterior, de nada serve predizer um movimento depois que ele já ocorreu. Uma vez aplicado o método online seria possível efetuar análises pertinentes como a da relação uso contra taxa de acerto, proposta por (JIANG, 2014), por exemplo. Outra mudança interessante se daria em torno do algoritmo de otimização, tanto em relação ao critério de parada (que nesse trabalho foi fixo para todos os treinos de modelo) quanto em relação ao algoritmo de otimização em si, que neste trabalho utilizou descida do gradiente. Seria de grande interesse avaliar outros métodos e testar a sua convergência. Em seu trabalho, (LOPES, 2014) apresenta uma abordagem interessante utilizando L-BFGS (*Limited-memory Broyden-Fletcher-Goldfarb-Shanno*). O objetivo desta melhoria seria manter ou melhorar a taxa

de acerto e aumentar a velocidade de convergência do algoritmo, mérito pelo qual, o método de descida do gradiente é famosamente ineficaz. Ainda em relação ao modelo, seria interessante elaborar testes mais aprofundados relacionando os parâmetros *alpha* e *lambda* com a taxa de acerto e se possível chegar em algum modelo analítico que pelo menos dê uma ideia aproximada de um valor numérico adequado para que não seja necessário investir tanto tempo em testes preliminares para determiná-los.

- Com relação a resultados, uma análise interessante não coberta pelo escopo deste trabalho é a avaliação do *delay* introduzido pelo sistema da leitura do sinal de sEMG, passando pela classificação e resultando na atuação do sistema. O *delay* do sistema pode inviabilizar a utilização experimental deste tipo de aparato, pois de nada adianta classificar o movimento e realiza-lo cinco ou dez segundos depois do momento propício.
- Quanto à variação de características, é um assunto que requer mais investigações, até porque somente três características foram utilizadas, oferecendo sete níveis internos de avaliação provenientes de suas variações. O principal problema deste tipo de estudo é a quantidade proibitiva de combinações geradas, portanto, seria recomendável fixar algum valor de variação dos canais utilizados e dentro deste testar a influência da variação de mais características, buscando alguma que proporcione uma maior estabilidade quanto a resposta ou uma maior taxa de acerto.
- Seria ainda bastante interessante que fossem realizados outros protocolos de aquisição da base IEE contemplando outros movimentos componentes da base NinaPro a fim de comparação de desempenho. Outra abordagem necessária a fim de comparação é a classificação destes dados através de outros métodos de

inteligência computacional. Atualmente estão sendo desenvolvidos alguns estudos no laboratório IEE para a comparação de resultados entre Regressão Logística, SVM e Lógica Paraconsistente utilizando as mesmas bases de dados utilizadas neste estudo.

## REFERÊNCIAS

- AHSAN, M. R.; IBRAHIMY, M. I.; KHALIFA, O. O. Neural network classifier for hand motion detection from EMG signal. In: INTERNATIONAL CONFERENCE ON BIOMEDICAL ENGINEERING, 5., 2011, Kuala Lumpur. **Proceedings...** Berlin: Springer, 2011. p. 536-541. v. 35.
- ARTEMIADIS, P. K.; KYRIAKOPOULOS, K. J. EMG-Based Control of a Robot Arm Using Low-Dimensional Embeddings. **IEEE Transactions on Robotics**. [S.l.], v. 26, n. 2, p. 393-398, abr. 2009. DOI: 10.1109/TRO.2009.2039378.
- ATZORI, M. et al. Building the Ninapro database: a resource for the biorobotics community. In: INTERNATIONAL CONFERENCE ON BIOMEDICALROBOTICS AND BIOMECHATRONICS (BioRob), 4., 2012, Rome. **Proceedings...** [S.l.]: IEEE, 2012. p.1258-1265.
- ATZORI, M.; et al. **Electromyography data for non-invasive naturally-controlled robotic hand prostheses**. **NatureScientific Data**. [S.l.], n. 1, v. 1, p. 1-13, 2014. Disponível em: <<http://www.nature.com/articles/sdata201453>>. Acesso em: 13 fev. 2015. DOI: 10.1038/sdata.2014.53.
- BALBINOT, A.; FAVIEIRO, G. A Neuro-Fuzzy System for Characterization of Arm Movements. **Sensors**. Basel, v. 13, n.2, p. 2613-2630, 2013.
- BASMAJIAN, J.V.; DE LUCA, C.J **Muscles alive: their functions revealed by electromyography**. Baltimore: Williams & Wilkins, 1985.
- BELTRAMINI, L. M. **Elementos de Histologia e Anátomo-Fisiologia Humana**. São Carlos, SP: Serviço Gráfico do Instituto de Física de São Carlos - USP, 1997. v. 1, 270 p.
- BENEDETTI, M. G. Muscle activation intervals and EMG envelope in clinical gait analysis. **IEEE Engineering in Medicine and Biology Magazine**. [S.l.] v. 20, n. 6, p. 33–34, Nov. 2001.
- BISHOP, C. M. **Pattern Recognition and Machine Learning**. New York: Springer, 2006.
- BRONZINO, J.; ENDERLE, J. **Introduction to Biomedical Engineering**. 3rd. ed. Burlington: Elsevier, 2012.
- BU, N.; OKAMOTO, M.; TSUJI, T. A hybrid motion classification approach for EMG-based human-robot interfaces using Bayesian and neural networks. **IEEE Transactions on Robotics**, v. 25, n. 3, p. 502–511, Jun. 2009.
- CHI, Y. et al. Binary Data Embedding Framework for Multiclass Classification. **IEEE Transactions On Human-Machine Systems**. [S.l.] v. 45, n. 4, p. 453-464, Ago. 2015.
- CHIANG, J.; WANG, J.; MCKEOWN, M.J.A Hidden Markov, Multivariate Autoregressive (HMM-MAR) Network Framework for Analysis of Surface EMG (sEMG) Data. **IEEE Transactions on Signal Processing**, v. 56, n.8, p. 4069-4081, Aug. 2008. DOI: 10.1109/TSP.2008.925246



- CENE, V. H.; FAVIEIRO, G.; BALBINOT A. Upper-limb Movement Classification Based on sEMG Signal Validation with Continuous Channel Selection. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 37., 2015, Milan. **Proceedings...** [S.l.]: IEEE,2015. p. 486-489, DOI: 10.1109/EMBC.2015.7318405.
- CRAM, J.R. The History of Surface Electromyography. **Applied Psychophysiology and Biofeedback**. New York, v. 28, n. 2, jun. 2003.
- DE-LUCA, C J. et al. Filtering the surface EMG signal: Movement artifact and baseline noise contamination. **Journal of Biomechanics**, New York, v.43, n.8, p. 1573-1579, 2010.
- DU, K.-L.; SWAMY, M. N. S. **Neural Networks and Statistical Learning**. London: Springer, 2014. DOI: 10.1007/978-1-4471-5571-3.
- ENDERLE, J. D. Senior Design for Persons with Disabilities: Student Projects That Improve Quality of Life. **IEEE Engineering In Medicine And Biology Magazine**. [S.l.] v. 25, n. 3, p. 25-29, 2006. DOI: 10.1109/MEMB.2006.1636346.
- EL-KOKA, A., ERA K. & KANG, D. EL-KOKA. Regularization Parameter Tuning Optimization Approach. In: INTERNATIONAL CONFERENCE ON ADVANCED COMMUNICATION TECHNOLOGY (ICACT), 15., 2013, PyeongChang. **Proceedings...** [S.l.]: IEEE, 2013. p. 13-18, 2013.
- ENGLEHART, K. et al. Classification of Myoelectric Signal using Time-Frequency Based Representations. **Medical Engineering & Physics**, New York, v. 21, n. 6, p. 431-438, 1999.
- FAVIEIRO G. W. **Desenvolvimento de um sistema neuro-fuzzy para análise de sinais mioelétricos do segmento mão-braço**. 2012. 142p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2012.
- FARREL T. R. Determining delay created by multifunctional prosthesis controllers. **Journal of Rehabilitation Research & Development**, Washington, DC, v. 48, n. 6, p. 21-37, 2011.
- FIELD, A. **Descobrimos a Estatística Utilizando o Spss**. 2. ed. Porto Alegre: Artmed, 2009. ISBN: 9788536319278.
- GIJSBERTS, A. et al. The Movement Error Rate for Evaluation of Machine Learning Methods for sEMG-based Hand Movement Classification. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, Piscataway, NJ, v. 22, n. 4, p. 735-744, 2014. DOI: 10.1109/TNSRE.2014.2303394.
- GUVENÇ, S.A.; DEMIR, M.; ULUTAS, M. Detection of forearm movements using wavelets and Adaptive Neuro-Fuzzy Inference System (ANFIS). In: INTERNATIONAL SYMPOSIUM ON INNOVATIONS IN INTELLIGENT SYSTEMS AND APPLICATIONS (INISTA), 2014, Alberobello. **Proceedings...** [S.l.]: IEEE, 2014. p. 192-196.
- GUYTON, A. C. **Fisiologia Humana**. 11. ed. Rio de Janeiro: Guanabara Koogan, 2006.
- HAN, H.; JO, S. Supervised Hierarchical Bayesian Model-Based Electromyographic Control And Analysis. **IEEE Journal of Biomedical and Health Informatics**, [S.l.], v. 18, n. 4, p. 1214-1224, 2014.
- HAYKIN, S. **Redes Neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.
- HUANG, Y.; ENGLEHART, K. B. A Gaussian mixture model based classification scheme for myoelectric control of powered upper limb prostheses. **IEEE Transactions on Biomedical Engineering**, New York, v. 52, n. 11, p. 1801–1811, Nov.2005.

HUDGINS, B.; PARKER, P.; SCOTT, R. A new strategy for multifunction myoelectric control. **IEEE Transactions on Biomedical Engineering**, New York, v. 40, n. 1, p. 82–94, 1993.

HSU, C. W.; CHANG, C. C.; LIN, C. J. **A Practical Guide to Support Vector Classification**. Taipei: Department of Computer Science and Information Engineering National Taiwan University, 2003. Disponível em: <<http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>>. Acesso em: 13 jun. 2015.

ISON, M.; ARTEMIADIS, P. The role of muscle synergies in myoelectric control: trends and challenges for simultaneous multifunction control. **Journal of Neural Engineering**, 2014. Doi:10.1088/1741-2560/11/5/051001.

JIANG, N. et al. Is accurate mapping of EMG signals on kinematics needed for precise online myoelectric control. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**. [S.l.], v. 22, n. 3, p. 549-558, 2014.

KHEZRI, M.; JAHED, M. A novel approach to recognize hand movements via sEMG patterns. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 29., 2007, Lyon. **Proceedings...** [S.l.]: IEEE, 2007. p. 4907-4910. DOI: IEMBS.2007.4353440.

KIGUCHI, K.; TANAKA T.; FUKUDA, T. Neuro-fuzzy control of a robotic exoskeleton with EMG signals. **IEEE Transactions on Fuzzy Systems**. [S.l.], v. 12, n. 4, p. 481–490, Aug. 2004.

KIM, H.K., et al. Continuous Shared Control for Stabilizing Reaching and Grasping With Brain-Machine Interfaces. **IEEE Transactions on Biomedical Engineering**, New York, v. 53, n. 6, p. 1164–1173, Jun. 2006.

KRISHNAMOORTHY, V. et al. Muscle synergies during shifts of the center of pressure by standing persons: identification of muscle modes. **Biological Cybernetics**, v. 89, n.2, p. 152–161, 2003.

KWON, S.; KIM, J. Real-time upper limb motion estimation from surface electromyography and joint angular velocities using an artificial neural network for human-machine cooperation. **IEEE Transactions Information Technology in Biomedicine**. [S.l.], v. 15, n. 4, p. 522–520, 2011.

LAVALLEY, M. P. Logistic Regression. **Circulation: American Heart Association Journals**. Boston, v. 117, n. 18, p. 2395-2399, 2008. DOI: 10.1161/ CIRCULATIONAHA.106.682658.

LEE, W. S.; LIU, B. Learning with Positive and Unlabeled Examples Using Weighted Logistic Regression. In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING (ICML-2003), 20., 2003, Washington. **Proceedings...** [S.l.: s.n.], 2003.

LI, G. et al. Performance of electromyography recorded using textile electrodes in classifying arm movements. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 33., Boston, 2011. **Proceedings...** Boston: EMBS, 2011, p. 4243 – 4246.

LINS, R.G. et al. Development and implementation of a natural interface to control an industrial hydraulic robot arm. In: ANNUAL IEEE INTERNATIONAL SYSTEMS CONFERENCE (SYSCON), 9., 2015, Vancouver. **Proceedings...** [S.l.]: IEEE, 2015, p. 766–772.

- LIU, J. Feature dimensionality reduction for myoelectric pattern recognition: A comparison study of feature selection and feature projection methods. **Medical Engineering & Physics**. Burlington: Elsevier, v. 36, n. 12, p. 1716-1720, 2014.
- LIU, W. Natural User Interface- Next Mainstream Product User Interface. In: IEEE INTERNATIONAL CONFERENCE OF COMPUTER-AIDED INDUSTRIAL DESIGN & CONCEPTUAL DESIGN (CAIDCD), 11., 2010, Yiwu. **Proceedings...** [S.l.]: IEEE, 2010.v. 1, p. 203–205.
- LOCK, B.; ENGLEHART, K.; Hudgins, B. Real-time myoelectric control in a virtual environment to relate usability vs. accuracy. In: MEC SYMPOSIUM CONFERENCE, 2., 2005, Fredericton. **Proceedings...** New Brunswick: University of New Brunswick, 2005. p. 4842 – 4845.
- LOPES, I. F **Caracterização dos sinais mioelétricos dos movimentos do segmento mão-braço através de regressão logística**. 2014. 123p. Trabalho de conclusão (Graduação) – Universidade Federal do Rio Grande do Sul. Escola de Engenharia. Departamento de Engenharia de Computação, Porto Alegre, 2014.
- LORENA A. C.; CARVALHO, A. C. P. L. F. de; GAMA J. M. P. A review on the combination of binary classifiers in multiclass problems. **Artificial Intelligence Review**. [S.l.]: Springer, v. 30, p. 19-37, 2008. DOI 10.1007/s10462-009-9114-9.
- MALMIVUO, J.; PLONSEY, R. **Bioelectromagnetism**: principles and applications of bioelectric and biomagnetic fields. 1<sup>st</sup>ed. New York: Oxford University Press, 1995. ISBN-13: 978-0195058239.
- MCLESTER, J. & ST. PIERRE, P. **Applied Biomechanics**. 1<sup>st</sup> ed. Belmont: Wadsworth, 2007
- MEULDERS, A.; et al. Generalization Gradients in Cued and Contextual Pain-Related-Fear: An experimental study in healthy participants. **Frontiers in Human Neuroscience**. Lausanne, v. 7, p. 345, 2013. DOI: 10.3389/fnhum.2013.00345.
- MICERA, S.; SABATINI, A.M.; DARIO, P. On automatic identification of upper-limb movements using small-sized training sets of EMG signals. **Medical Engineering & Physics – Journal**. Burlington, v. 22, n. 8, p. 527–533, Oct.2000.
- MOFARREH-BONAB, M.; GHORASHI, S. A. A Low Complexity and High Speed Gradient Descent Based Secure Localization in Wireless Sensor Networks. In: INTERNATIONAL CONFERENCE ON COMPUTER AND KNOWLEDGE ENGINEERING (ICCCKE), 3., Mashhad, 2013. **Proceedings...** [S.l.]: IEEE, 2013, p. 300-303. DOI: 10.1109/ICCCKE.2013.6682841
- MOHAMMADREZA, A.O.; HUOSHENG, H. Myoelectric control systems: a survey. **Biomedical Signal Processing and Control**. Oxford, v.2, n. 4, p. 275 –294, 2007.
- MONTGOMERY, D. C. **Design and analysis of experiments**. 8<sup>th</sup>. ed. New York: Wiley, 2013.
- MOORE, J.; ZOURIDAKIS, G. **Biomedical Technology and Devices Handbook**. Boca Raton: CRC Press LLC, 2004. 840 p.
- MUCELI, S; FARINA, D. Simultaneous and Proportional Estimation of Hand Kinematics from EMG during Mirrored Movements at Multiple Degrees-of-Freedom. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**. [S.l.], v. 20, n. 3, p. 371 – 378, 2012. DOI: 10.1109/TNSRE.2011.2178039.

NAIK, G. R. (Ed.). **Computational Intelligence in Electromyography Analysis: A Perspective on Current Applications and Future Challenges**. 1<sup>st</sup>. ed. Vienna: InTech, 2012. Doi: 10.5772/48793.

NAIK, G.R.; DINESH, K. Identification of hand and finger movements using multi run ICA of surface electromyogram. **Journal of medical systems**. New York, v. 36, n. 2, p. 841-851, 2012.

NAIK, G.R.; BAKER, K.G.; NGUYEN, H.T. Dependence Independence measure for posterior and anterior EMG sensors used in simple and complex finger flexion movements: evaluation using SDICA. **IEEE Journal of Biomedical and Health Informatics**. [S.l.], v. 19, n. 5, p. 1689-1696, 2015. Doi: 10.1109/JBHI.2014.2340397.

NAIK, G.R.; DINESH, K.; MARIMUTHU, P. Signal processing evaluation of myoelectric sensor placement in low-level gestures: sensitivity analysis using independent component analysis. **Expert Systems**. Hoboken, v. 31, n. 1, p. 91-99, 2014.

NG, A. **Machine Learning**. Stanford University. Stanford, 2014. Disponível em: <www.coursera.org>. Acesso em: 20 maio 2015.

NILSON, C. P. **Aquisição, processamento de sinais mioelétricos e máquina de vetores de suporte para caracterização de movimentos do segmento mão-braço**. 2014. 88p. Dissertação (Mestrado) – Universidade Federal do Rio Grande do Sul. Escola de Engenharia. Departamento de Engenharia Elétrica, Porto Alegre, 2014.

ORTOLAN, R. L. **Estudo e avaliação de técnicas de processamento do sinal mioelétrico para o controle de sistemas de reabilitação**. 2002. 117 f. Tese (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade de São Paulo, São Carlos, 2002.

OSBORN, B. S. L.; NITISH, V.T.; KALIKI, R. Utilizing Tactile Feedback for Biomimetic Grasping Control in Upper Limb Prostheses. **Sensors**. Baltimore, p. 1-4., 2013. MD. DOI: 10.1109/ICSENS.2013.6688445.

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

QICHUAN, D. et al. Missing-Data Classification With the Extended Full-Dimensional Gaussian Mixture Model: Applications to EMG-Based Motion Recognition. **IEEE Transactions on Industrial Electronics**. [S.l.], v. 62, n. 8, p. 4994-5005, 2015. DOI: 10.1109/TIE.2015.2403797.

RAJESH, V.; KUMAR, P.R. Hand gestures recognition based on SEMG signal using wavelet and pattern recognition. **International Journal of Recent Trends in Engineering**. [S.l.], v. 1, n. 4, p. 26–28, 2009.

SANGER, T. D. Bayesian filtering of myoelectric signals. **Journal of Neurophysiology**. [S.l.], v. 97, p. 1839–1845, 2007.

STARR, C.; MCMILAN, B. **Human Biology**. 11<sup>th</sup>. ed. Boston: Brooks Cole, 2015.

STAUDENMANN, D. et al. Increase in heterogeneity of biceps brachii activation during isometric submaximal fatiguing contractions: a multichannel surface EMG study. **Journal of Neurophysiology**. [S.l.], v. 111, n. 5, p. 984-990, 2014.

TENORE, F. et al. Towards the control of individual fingers of a prosthetic hand using surface EMG signals. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 30., Lyon, 2007. **Proceedings...** [S.l.]: IEEE, Aug 2007, p. 6145–6148.

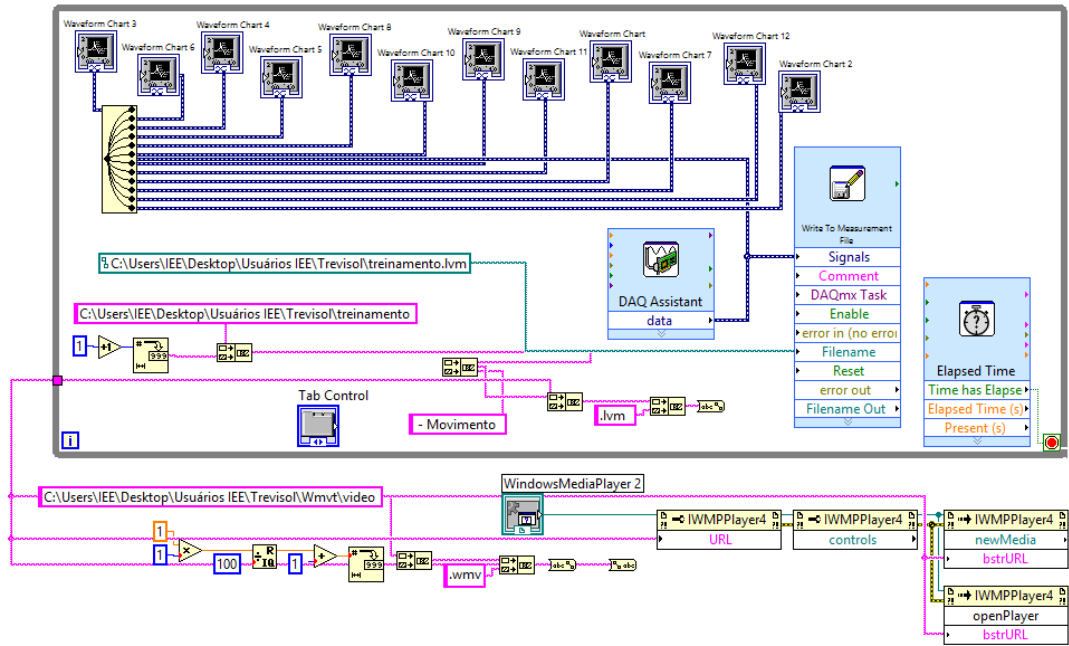
TORTORA, G. J. **Princípios de Anatomia Humana**. 10. ed. Rio de Janeiro: Guanabara Koogan, 2007.

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

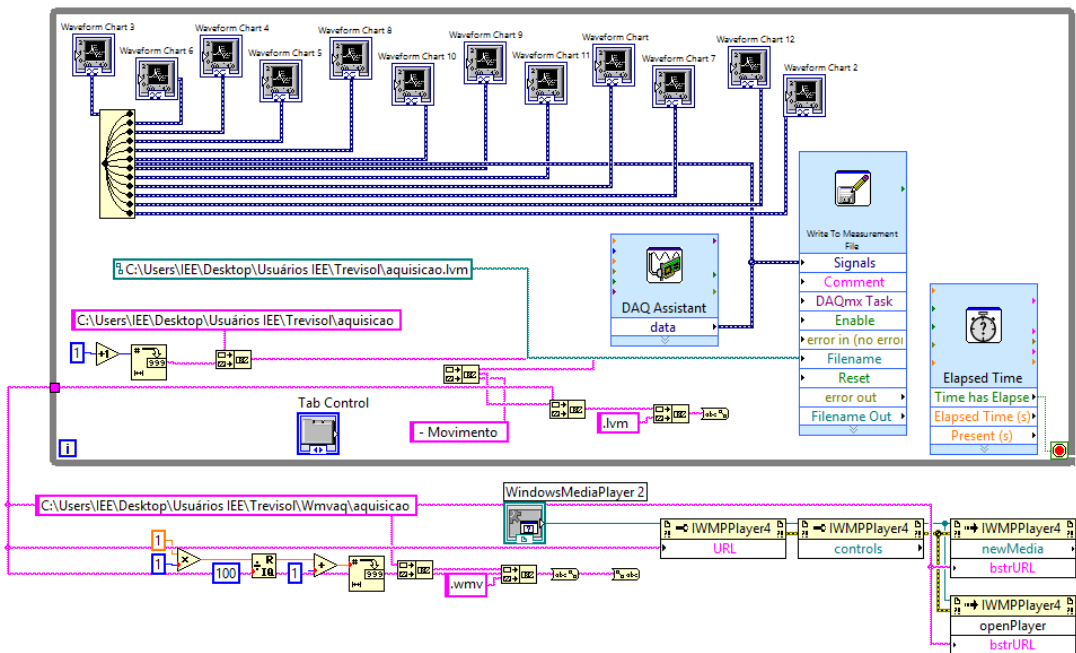
ZHANG, X.; HUANG, H. A real-time, practical sensor fault-tolerant module for robust emg pattern recognition. **Journal of Neuroengineering and Rehabilitation**. [S.l.], v.12, n. 1, 2015. Doi: 10.1186/s12984-015-0011-y.

## APÊNDICE A - PROGRAMAÇÃO REALIZADA EM LABVIEW PARA AS ETAPAS DE TREINO E AQUISIÇÃO DE DADOS

Programação realizada em LaVIEW para o treino do voluntário:



Programação realizada em LaVIEW para a aquisição de dados do voluntário:



## **APÊNDICEB - TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO**

### **Termo de Consentimento Livre Esclarecido**

Nome do Projeto: Processamento de Sinais Através de Regressão Logística Para Classificação de Movimentos de Membro Superior.

Pesquisador Responsável: Dr. Alexandre Balbinot.

Pesquisadores/Assistentes/Alunos: Eng. Vinícius Horn Cene e Fernanda Trevisol.

As informações contidas nesta folha, fornecidas por Alexandre Balbinot têm por objetivo firmar acordo escrito com o(a) Voluntário(a) para participação da pesquisa acima referida, autorizando sua participação com pleno conhecimento da natureza dos procedimentos a que ele(a) será submetido(a).

1. Natureza da Pesquisa: Esta pesquisa tem como finalidade o desenvolvimento de uma plataforma de tecnologia assistiva para avaliação de sinais mioelétricos do segmento mão-braço por métodos matemáticos para possibilitar futuramente o controle de dispositivos auxiliares na reabilitação de amputados.
2. Envolvimento na Pesquisa: ao participar dessa pesquisa o senhor(a) estará auxiliando o desenvolvimento das pesquisas na área de instrumentação biomédica. O senhor(a) tem liberdade de se recusar a participar e ainda de recusar a continuar participando em qualquer fase da pesquisa, sem lhe ocasionar qualquer prejuízo. Sempre que quiser poderá pedir mais informações sobre a pesquisa através do telefone dos pesquisadores e do projeto.
3. Protocolo experimental: Inicialmente será realizada uma breve anamnese (entrevista), onde apenas os pesquisadores terão conhecimento dos dados informados. Posteriormente será posicionado no braço e antebraço do Voluntário eletrodos de superfície, um vídeo será rodado informando os movimentos que devem ser realizados. Durante esse procedimento, estaremos adquirindo, através de um eletromiógrafo, os sinais mioelétricos do Voluntário, sendo esse o dado utilizado nesta pesquisa.
4. Riscos e desconfortos: Os procedimentos adotados nesta pesquisa obedecem aos Critérios da Ética em Pesquisa com Seres Humanos conforme Resolução nº.196/96 do Conselho Nacional de Saúde. O procedimento adotado pode causar uma leve fadiga muscular.
5. Confidencialidade: as informações neste estudo são estritamente confidenciais. Os dados do Voluntário serão identificados com um código e não com o nome. Somente os pesquisadores e o orientador desta pesquisa terão conhecimento dos dados.
6. Benefícios: Ao participar desta pesquisa você não terá nenhum benefício direto. Entretanto, esperamos que este estudo contribua com informações e elementos importantes à literatura e ao desenvolvimento da tecnologia assistiva, onde o pesquisador se compromete a divulgar os resultados obtidos.
7. Garantia de acesso: em qualquer etapa do estudo, você terá acesso aos profissionais responsáveis pela pesquisa para esclarecimento de eventuais dúvidas. O Pesquisador Responsável é o Dr. Eng. Alexandre Balbinot, que pode ser encontrado no endereço Av. Osvaldo Aranha 103 sala 206 D, POA/RS (UFRGS) Telefone 33083326.

8. Despesas e compensações: não há despesas pessoais para o participante em qualquer fase do estudo, incluindo exames e consultas. Também não há compensação financeira relacionada à sua participação. Se existir qualquer despesa adicional, ela será absorvida pelo orçamento da pesquisa.
9. Liberdade de recusar ou retirar consentimento: Você tem a liberdade de retirar seu consentimento a qualquer momento e deixar de participar do estudo sem penalização.
10. Os dados obtidos são de livre uso do grupo de pesquisadores, ou seja, podem ser publicados e utilizados no desenvolvimento de trabalhos científicos. Porém em nenhum momento serão tornados públicos os dados pessoais do Voluntário.

Após estes esclarecimentos, solicitamos o seu consentimento de forma livre para permitir sua participação nesta pesquisa.

### **Consentimento Livre e Esclarecido**

Eu \_\_\_\_\_ portador do RG \_\_\_\_\_, de forma livre e esclarecida, manifesto meu consentimento em participar da pesquisa em participar nesse estudo. Ficaram claros para mim quais são os propósitos do estudo, os procedimentos a serem realizados, seus desconfortos e riscos, as garantias de confidencialidade e de esclarecimentos permanentes. Ficou claro também que minha participação é isenta de despesas. Concordo voluntariamente em participar deste estudo e poderei retirar o meu consentimento a qualquer momento, antes ou durante o mesmo, sem penalidades ou prejuízo ou perda de qualquer benefício que eu possa ter adquirido, ou no meu atendimento neste Serviço. Declaro que recebi cópia deste termo de consentimento, e autorizo a realização da pesquisa e a divulgação dos dados obtidos neste estudo.

**Local e data** \_\_\_\_\_, \_\_\_\_/\_\_\_\_/\_\_\_\_\_

\_\_\_\_\_  
Assinatura do Participante da Pesquisa

\_\_\_\_\_  
Assinatura do Pesquisador Responsável- Dr. Alexandre Balbinot.

Pesquisador Principal: Alexandre Balbinot – Tel:

Demais pesquisadores: Vinícius Horn Cene - Tel:

Fernanda Trevisol -Tel:



**APÊNDICE C - ANAMNESE**

---

**Identificação**

---

**Nome:**

**RG:**

**Idade:** **Idade em que ocorreu a amputação:**

**Altura:** **Peso:** **Sexo:** **Cor:**

**Naturalidade:**

**Profissão :** **Profissão antes da amputação:**

**Estado Civil:**

**Escolaridade:**

---

**Contato**

---

**Endereço:**

**Bairro:** **CEP:**

**Cidade:** **Estado:**

**Telefone:**

**e-mail:**

---