

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

**CLAIRÊ DE PAULI NILSON**

**AQUISIÇÃO, PROCESSAMENTO DE SINAIS  
MIOELÉTRICOS E MÁQUINA DE VETORES DE  
SUPORTE PARA CARACTERIZAÇÃO DE  
MOVIMENTOS DO SEGMENTO MÃO-BRAÇO**

Porto Alegre

2014

**CLAIRÊ DE PAULI NILSON**

**AQUISIÇÃO, PROCESSAMENTO DE SINAIS  
MIOELÉTRICOS E MÁQUINA DE VETORES DE  
SUPORTE PARA CARACTERIZAÇÃO DE  
MOVIMENTOS DO SEGMENTO MÃO-BRAÇO**

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: Controle e Automação;  
subárea: Instrumentação

ORIENTADOR: Prof. Dr. Eng. Alexandre Balbinot

Porto Alegre

2014

CLAIRÊ DE PAULI NILSON

**AQUISIÇÃO, PROCESSAMENTO DE SINAIS  
MIOELÉTRICOS E MÁQUINA DE VETORES DE  
SUPORTE PARA CARACTERIZAÇÃO DE  
MOVIMENTOS DO SEGMENTO MÃO-BRAÇO**

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. Eng. 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. Leticia Vieira Guimarães, UERGS

Doutora pela Muroran Institute of Technology – Hokkaido, Japão

Prof. Dr. Walter Fetter Lages, UFRGS

Doutor pelo ITA – São José dos Campos, Brasil

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

Prof. Dr. João Manoel Gomes da Silva Júnior

Porto Alegre, Abril de 2014.

## DEDICATÓRIA

Dedico este trabalho a Deus, o autor e criador da vida, por ter me dotado de capacidade, persistência e inteligência. Também ao meu companheiro e amigo, Jerônimo Nilson, e às minhas duas lindas e queridas filhas, Laura Nilson e Mariana Nilson, por me ajudarem com suas orações e por compreenderem minha ausência e por sempre me apoiarem e me incentivarem a avançar e prosseguir rumo ao alvo.

*The fear of the LORD is the beginning of wisdom, and knowledge of the Holy One  
is understanding. Provérbios 9:10*

*νυνι δε μενει πιστις ελπις αγαπη τα τρια ταυτα μειζων δε τουτων η αγαπη.*

1 Coríntios 13:13

## **AGRADECIMENTOS**

Aos meus pais, *in memoriam*, que sempre me ensinaram a nunca desistir.

A toda minha família e amigos pela torcida e espera.

Ao professor Dr. Alexandre Balbinot, pela oportunidade e privilégio únicos de poder ser e fazer parte da história da Universidade Federal do Rio Grande do Sul.

Aos meus colegas do IEE por compartilharem suas experiências e conhecimentos.

E a todos aqueles que colaboraram, de uma forma ou de outra, para o cumprimento desta jornada de aprendizado e oportunidades.

## RESUMO

As diversas áreas da Engenharia, em parceria com a ciência médica, têm contribuído de forma eficaz para o avanço do conhecimento e dos resultados em aplicações práticas na vida do deficiente físico. De forma geral, pesquisas com este foco têm permitido o desenvolvimento de dispositivos e recursos com o objetivo de oferecer novamente a mobilidade e a liberdade perdidas com a deficiência. Este trabalho tem a finalidade de desenvolver um sistema que utiliza Eletromiografia de Superfície e Máquina de Vetores de Suporte para a caracterização de determinados movimentos de um braço humano, possibilitando, futuramente, a integração em sistemas de reabilitação. Primeiramente os sinais mioelétricos são obtidos nos músculos do braço de voluntários através de eletrodos de superfície ligados a um eletromiógrafo. O sinal é adquirido, utilizando como padrão um modelo virtual que demonstra ao voluntário os movimentos do segmento mão-braço que devem ser imitados. Esses movimentos são executados e seus sinais mioelétricos adquiridos. Posteriormente, esses sinais são processados e características são extraídas. Em seguida, são alocadas algumas de suas características (RMS, média, variância, desvio padrão, *skewness* e *kurtosis*) na entrada da Máquina de Vetores de Suporte, que apresenta, como saída, o reconhecimento, ou não, do movimento previamente executado pelo voluntário. No final do processo, observou-se que aumentando o número de canais elevou-se a taxa de acerto dos movimentos e, com a retirada de determinada característica, houve decréscimo na taxa de acerto do sistema. Nestes casos, os 9 movimentos distintos atingiram uma taxa de acerto média de 83,2%, para dois canais, e 91,3%, para oito canais, e, em ambos sistemas de canais, com as seis características.

**Palavras-chave:** Caracterização de movimentos do segmento mão-braço, Instrumentação Biomédica, Eletromiografia, Máquina de Vetores de Suporte.

## **ABSTRACT**

A wide range of engineering scopes, along with the knowledge from the medical science, has efficiently been contributing to further knowledge and results for practical applications in the life of the physically challenged. In general, such researches have allowed the development of devices and resources aimed at giving back the mobility and freedom lost with the deficiency. This paper intends to develop a system that uses Surface Electromyography and Support-Vector Machines (SVM) for the characterization of specific movements of a human arm enabling the future integration in rehabilitation systems. At first, myoelectric signals are obtained in the arm muscles of volunteers by means of surface electrodes attached to an Electromyography. The signal is acquired using a virtual model as pattern demonstrating to the volunteer the hand-arm movements which are to be replicated by the subject. As these movements are done, its respective myoelectric signals are acquired. Later on, these signals are processed and their characteristics extracted. Some of these features (such as RMS, standard deviation, variance, mean, kurtosis, skewness) will then be inserted in as input data in the Support-Vector Machine, which shows as an output a valid or null recognition of the movement earlier executed by the volunteer. At the end of the process, it was observed that increasing the number of channels increased by hit rate movements and, with the removal of certain characteristic, there was a decrease in the hit rate of the system. In these cases, nine distinct movements reached an average accuracy of 83.2% for two channels, and 91.3% for eight channels, and in both systems of channels, with six features.

**Keywords: Movement Characterization of Hand-arm Segment, Biomedical Instrumentation, Electromyography, Support-Vector Machine.**

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>14</b>
1.1	JUSTIFICATIVA	15
1.2	OBJETIVOS	16
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>17</b>
2.1	ELETROMIOGRAFIA (EMG)	18
2.2	IMPULSO NERVOSO OU POTENCIAL DE AÇÃO NERVOSO	20
2.3	CONTRAÇÃO E RELAXAMENTO DOS MÚSCULOS	21
2.4	MÁQUINAS DE VETORES DE SUPORTE (SVM)	24
2.4.1	Hiperplano de Separação	25
2.4.2	Função <i>Kernel</i>	31
2.4.3	Classificação com mais de duas classes	33
2.5	OUTROS TRABALHOS QUE UTILIZARAM EMG PARA CARACTERIZAR O MOVIMENTO DO SEGMENTO MÃO-BRAÇO	34
<b>3</b>	<b>METODOLOGIA EXPERIMENTAL</b>	<b>39</b>
3.1	MODELO VIRTUAL	40
3.1.1	Movimentos Simples	41
3.1.2	Movimentos Compostos	42
3.1.3	Séries de Movimentos	42
3.2	ROTINA PARA EXECUTAR VÍDEOS E ADQUIRIR DADOS	43
3.3	POSICIONAMENTO DOS ELETRODOS DE SUPERFÍCIE	49
3.4	PRÉ- PROCESSAMENTO DO SINAL DE EMG	49
3.4.1	Ajuste de <i>offset</i> e Filtragem Digital	50
3.4.2	Normalização do Sinal de EMG	51
3.4.3	Segmentação	52
3.4.4	Extração de Características do Sinal de EMG	56
3.5	PROCESSAMENTO DO SINAL UTILIZANDO A SVM	58
3.5.1	Dimensionamento da SVM	58
3.5.2	Treinamento da SVM	59
3.5.3	Validação Cruzada	59
3.5.4	Matriz de Confusão	60
<b>4</b>	<b>RESULTADOS E DISCUSSÕES</b>	<b>63</b>
4.1	SINAIS ADQUIRIDOS COM DOIS CANAIS	63
4.1.1	Voluntário I	64
4.1.2	Voluntário II	68
4.1.3	Voluntário III	70
4.2	SINAIS ADQUIRIDOS COM OITO CANAIS	73
4.2.1	Voluntário I	74
4.2.2	Voluntário II	76
4.3	VARIANDO AS CARACTERÍSTICAS UTILIZADAS	78
4.3.1	Análise sem RMS	79
4.3.2	Análise sem <i>Kurtosis</i>	80
4.3.3	Análise sem <i>Skewness</i>	81
4.3.4	Análise sem Variância	81
4.4	COMPARAÇÃO DOS RESULTADOS DESTE TRABALHO COM OUTROS ESTUDOS	82

<b>5</b>	<b>CONCLUSÕES.....</b>	<b>84</b>
<b>6</b>	<b>PROPOSTA PARA TRABALHOS FUTUROS.....</b>	<b>85</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>86</b>

## LISTA DE ILUSTRAÇÕES

Figura 1	Fibras musculares esqueléticas (adaptado de GUYTON, 2006).....	18
Figura 2	Unidade motora e EMG: (1) fibras musculares ligadas aos neurônios formando unidades motoras e (2) EMG com seus respectivos valores de tensão elétrica (Adaptado de PATTEN, 2000). ....	19
Figura 3	Registro de alteração de potencial de um impulso nervoso (Adaptado de TORTORA, 2000). ....	21
Figura 4	Movimento do antebraço erguendo um peso (adaptado de TORTORA, 2000). ....	22
Figura 5	Principais músculos superficiais do braço e antebraço (TORTORA, 2000). ....	23
Figura 6	Vetores de Suporte e Hiperplano Ótimo (HAYKIN, 2001).....	26
Figura 7	Interpretação geométrica das distâncias algébricas de pontos até o Hiperplano Ótimo (Adaptado de HAYKIN, 2001). ....	28
Figura 8	Hiperplano Ótimo com classes distintas e as equações (Adaptado de HAYKIN, 2001). ....	29
Figura 9	(a) O ponto de dado se encontra dentro da região de separação e no lado correto. (b) O ponto de dado se encontra do lado errado da superfície de decisão (HAYKIN, 2001). ....	30
Figura 10	Arquitetura de uma SVM não linear (HAYKIN, 2001).....	32
Figura 11	Diagrama de blocos do sistema proposto.....	39
Figura 12	Fotos representando os movimentos simples: (1) zoom da mão: (a) contração da mão, (b) extensão do pulso, (c) supinação, (d) flexão do punho, (e) flexão do antebraço e (2) posição de repouso (Adaptado de FAVIEIRO, 2009). ....	41
Figura 13	Modelo Virtual representado os movimentos simples: (1) zoom da mão: (a) contração da mão, (b) extensão do pulso, (c) supinação, (d) flexão do punho, (e) adução do punho, (f) abdução do punho, (g) flexão do antebraço e (2) posição de repouso. (FAVIEIRO, 2013). ....	41
Figura 14	Gráfico contendo a sequência de movimentos (Adaptado de BERMUDEZ, 2013). ....	43
Figura 15	Fluxograma da rotina de execução de vídeos e de aquisição de dados.....	44
Figura 16	Rotina do Modelo Virtual: (a) painel frontal do <i>LabView</i> e (b) painel diagrama de blocos do <i>LabView</i> : parte da rotina desenvolvida para a visualização das animações. ....	45
Figura 17	Rotina de aquisição de dados: (a) painel frontal do <i>LabView</i> e (b) painel diagrama de blocos. ....	46
Figura 18	Sinais de EMG adquiridos com dois canais executando a série G. ....	47
Figura 19	Sinais de EMG adquiridos com oito canais executando a série B. ....	48
Figura 20	Diagrama de Blocos de parte da etapa de Pré-Processamento.....	50
Figura 21	Fluxograma do ajuste de <i>offset</i> .....	51
Figura 22	Fluxograma do cálculo da normalização.....	51
Figura 23	Sinal DE EMG: (a) sinal original e (b) segmentação reconstituída sob a base de tempo do sinal original.....	54

Figura 24 (1.A) Exemplo do Sinal Mioelétrico do canal 1 executando a série D, (1.B) trecho do sinal indicando a contração da mão e flexão do antebraço e (2) série de movimentos (Adaptado de BERMUDEZ, 2013).....	55
Figura 25 Fluxograma do cálculo do valor RMS, média aritmética ( $\bar{X}$ ), variância ( $s^2$ ), desvio padrão ( $s$ ), <i>skewness</i> ( $sk$ ) e <i>kurtosis</i> ( $ku$ ).....	57
Figura 26 Saída da SVM para o Voluntário I, executando a série F.....	65
Figura 27 Saída da SVM para o Voluntário I, executando a série C.....	66
Figura 28 Saída da SVM para o Voluntário I, executando a série E.....	67
Figura 29 Saída da SVM para o Voluntário II, executando a série C.....	69
Figura 30 Saída da SVM para o Voluntário II, executando a série D.....	70
Figura 31 Saída da SVM para o Voluntário III, executando a série G.....	72
Figura 32 Saída da SVM para o Voluntário III, executando a série E.....	72
Figura 33 Saída da SVM para o Voluntário I, executando a série D.....	75
Figura 34 Saída da SVM para o Voluntário I, executando a série D.....	76
Figura 35 Saída da SVM para o Voluntário II, executando a série B.....	77
Figura 36 Saída da SVM para o Voluntário II, executando a série B.....	78

## LISTA DE TABELAS

Tabela 1 Principais músculos superficiais do braço, antebraço e suas funções. ....	24
Tabela 2 Os resultados de outros estudos. (Adaptado de BALBINOT, FAVIEIRO, 2013) .....	36
Tabela 3 Os resultados de outros estudos. (Adaptado de BALBINOT, FAVIEIRO, 2013) .....	37
Tabela 4 Os resultados de outros estudos. (Adaptado de BALBINOT, FAVIEIRO, 2013) .....	38
Tabela 5 Séries com seus respectivos movimentos (Adaptado de BERMUDEZ, 2013). ....	42
Tabela 6 Matriz de Confusão.....	61
Tabela 7 Taxa de acerto média do Voluntário I executando a série F.....	64
Tabela 8 Taxa de acerto média do Voluntário I executando a série C.....	64
Tabela 9 Taxa de acerto média do Voluntário I executando a série E.....	64
Tabela 10 Taxa de acerto média do sistema.....	67
Tabela 11 Taxa de acerto média do Voluntário II executando a série C.....	68
Tabela 12 Taxa de acerto média do Voluntário II executando a série D.....	68
Tabela 13 Taxa de acerto média do sistema.....	70
Tabela 14 Taxa de acerto média do Voluntário III executando a série F.....	71
Tabela 15 Taxa de acerto média do Voluntário III executando a série E.....	71
Tabela 16 Taxa de acerto média do sistema.....	73
Tabela 17 Taxa de acerto média do Voluntário I executando a série D.....	74
Tabela 18 Taxa de acerto média do Voluntário II executando a série B.....	76
Tabela 19 Taxa de acerto média sem RMS.....	79
Tabela 20 Taxa de acerto média sem a <i>kurtosis</i> .....	80
Tabela 21 Taxa de acerto média sem a <i>skewness</i> .....	81
Tabela 22 Taxa de acerto média sem a variância.....	82

## **LISTA DE ABREVIATURAS**

CM: Contração da Mão

CMF: Contração da Mão e Flexão do Antebraço

CVM: Contração Voluntária Máxima

DAQ: Data Acquisition

DWT: Discrete Wavelet Transform

EFP: Extensão e Flexão do Punho

EMG: Eletromiografia

EP: Extensão do Punho

Err: Erro

FA: Flexão do Antebraço

FP: Flexão do Punho

FP: Falso Positivo

FN: Falso Negativo

K<sup>+</sup>: Íons de Potássio

LabView: Laboratory Virtual Instrument Engineering

Matlab: MATrix LABORatory

MVA: Média do Valor Absoluto

MUAP: Motor Unit Action Potential

MUAPT: Motor Unit Action Potential Train

Na<sup>+</sup>: Íons de Sódio

RA: Rotação do Antebraço

RAC: Rotação do Antebraço e Contração da Mão

RBF: Radial Basis Function

RFA: Rotação/ Flexão do Antebraço

RMS: Root Mean Square

SME: Sinal Mioelétrico

SVM: Support-Vector Machines

Th: threshold

TVP: Taxa de VP

TVN: Taxa de VN

Txc: Taxa de acerto

VP: Verdadeiro Positivo

VN: Verdadeiro Negativo

VI : Instrumento Virtual

r: Sensitivity ou Recall

## 1 INTRODUÇÃO

O ser humano saudável, dotado de um corpo com estrutura física de membros articulados, que lhe oferece mobilidade, flexibilidade e uma infinidade de possibilidades, sempre mostrou-se capaz de utilizar os recursos disponíveis nesse organismo físico a fim de suprir e atender, com habilidade e inteligência, tanto suas necessidades de sobrevivência, de crescimento e de desenvolvimento próprios, quanto as da comunidade em que vive. Contudo, a falta de um membro do corpo limita essa capacidade, mas não a disposição criativa do homem. Técnicas de reabilitação humana, principalmente na área de desenvolvimento de tecnologia assistiva, têm evoluído de forma acentuada a fim de solucionar ou, ao menos, minimizar esse tipo de problema.

A seguir, algumas considerações e alguns estudos, baseados em pesquisas recentes, que serviram como base para este trabalho são apresentados:

- a) o movimento executado por determinado segmento do corpo humano resulta da contração e do relaxamento dos músculos (TORTORA, 2000);
- b) o sinal de EMG tem sua origem nas contrações dos principais músculos esqueléticos e são considerados sinais com maior estabilidade em comparação com outros sinais biológicos (YONGJIAN & BOQIANG LIU, 2010);
- c) os sinais mioelétricos transmitem informações que podem controlar próteses (FAVIEIRO & BALBINOT, 2012);
- d) a caracterização do sinal mioelétrico pode determinar o movimento realizado (YONGJIAN & BOQIANG LIU, 2010);

- e) tipos diferentes de eletrodos, músculos e nível de contração muscular podem variar a amplitude e a taxa de frequência dos sinais de EMG (ORTOLAN, 2002);
- f) sinais mioelétricos podem ser obtidos com eletrodos de superfície (FAVIEIRO & BALBINOT, 2012);
- g) a segmentação de sinais de EMG pode ser baseada na definição de um limiar de detecção (FAVIEIRO & BALBINOT, 2012);
- h) para se obter informações significativas do sinal de EMG é necessário tratá-lo matematicamente (MAZURKIEWICZ, 2007);
- i) a qualidade da classificação da SVM e, portanto, a taxa de acertos, é significativamente melhor do que o classificador de rede neural RBF (LIU, HUANG & LIU, 2010).

## 1.1 JUSTIFICATIVA

O desafio de desenvolver uma prótese robótica similar ao braço humano, controlada através de sinais mioelétricos, está baseado nas descobertas de pesquisadores como Boschmann, Kaufmann & Platzner (2009), Faviero & Balbinot (2012), Liu, Huang & Liu (2010), Mazurkiewicz (2007), Ortolan (2002), e Yongjian & Boqiang Liu (2010), que certificam a capacidade de amputados encontrarem-se aptos a gerar determinados sinais mioelétricos padronizados diante da intenção de realizar um específico movimento e que, através da caracterização desse sinal, é possível determinar movimentos e, ainda, que os sinais mioelétricos transmitem informações adequadas e podem comandar próteses.

## 1.2 OBJETIVOS

O objetivo deste trabalho é desenvolver um sistema que utiliza Eletromiografia de Superfície e Máquina de Vetores de Suporte para a caracterização de determinados movimentos de um braço humano, possibilitando, futuramente, a integração em sistemas de reabilitação.

Os objetivos específicos são:

- a) avaliar a relação entre o número de características com a taxa de acertos;
- b) avaliar a relação entre o número de canais de classificação com a taxa de acertos;
- c) comparar dois métodos de validação cruzada, *leave-one-out* e *k-fold*.

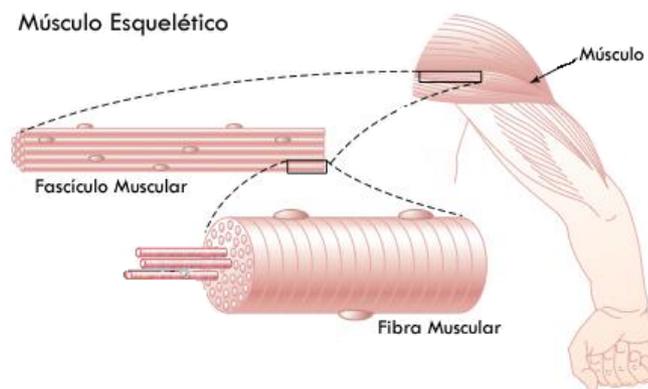
## 2 REVISÃO BIBLIOGRÁFICA

Segundo Ortolan (2002), muitas pesquisas foram certificadas para comprovar a existência de atividade elétrica durante a contração muscular. Em 1791, através de experimentos em sapos, o médico, físico e filósofo italiano Luigi Galvani provou a relação entre a contração muscular e a eletricidade, que deu origem a área da Neurofisiologia. Em 1838, Carlos Matteucci, utilizando um galvanômetro, ratificou que havia contração muscular em sapos com nervos intactos, estimulados a partir do toque no nervo, demonstrando assim, a existência de atividade elétrica em uma contração muscular. Em 1849, Frenchman Dubois-Reymond evidenciou, através de experimentos, a existência de um sinal elétrico quando um ser humano realizava um movimento voluntário com um dos braços. Assim, pode-se dizer que um Sinal Mioelétrico (SME) é um sinal elétrico existente nos músculos quando um ser humano realiza uma contração muscular. Em 1944, Hebert Gasser e Joseph Erlanger capturaram, através de um tubo de raios catódicos e eletrodos específicos, os Sinais Mioelétricos do corpo de um paciente e o apresentaram na tela de um osciloscópio. Com base nesta pesquisa e através do estudo da morfologia dos Sinais Mioelétricos, nasceu a Eletromiografia (EMG), como uma técnica de monitoramento da atividade elétrica dos músculos. Sendo assim, a EMG é um exame eletrofisiológico que consiste no registro, análise e interpretação da atividade bioelétrica do músculo em resposta a ativação voluntária.

Embora seus princípios já foram desenvolvidas no início do Século XX a Eletromiografia (EMG) tornou-se rapidamente conhecida e usada em muitas aplicações nas áreas de Neurologia, Reabilitação Motora, Ortopedia, Ergonomia e na área dos Esportes, nas quais os resultados da EMG de Superfície são combinados com medidas clínicas e achados laboratoriais, a fim de estabelecer diagnóstico e subsequente plano de tratamento (SENIAN, 2013).

## 2.1 ELETROMIOGRAFIA (EMG)

A EMG captura os potenciais de ação muscular utilizando uma técnica de monitoramento (registro, análise e interpretação) da atividade elétrica do músculo. Na Figura 1, pode-se observar o músculo esquelético composto por vários fascículos musculares e esses de várias fibras musculares. Um potencial de ação é enviado por um neurônio motor, tipo particular de neurônio, que estimula o tecido muscular, percorrendo as fibras musculares e formando um campo eletromagnético nas suas proximidades. O resultado da soma algébrica dos potenciais de ação de várias fibras de uma unidade motora, composta de um neurônio motor e todas as fibras musculares que estimula, é chamado potencial de ação da unidade motora, cuja sigla em inglês é MUAP (*Motor Unit Action Potential*). A estimulação de um neurônio motor faz todas as fibras musculares daquela unidade motora contrair-se simultaneamente na sua extensão total (GUYTON, 2006; TORTORA, 2000).

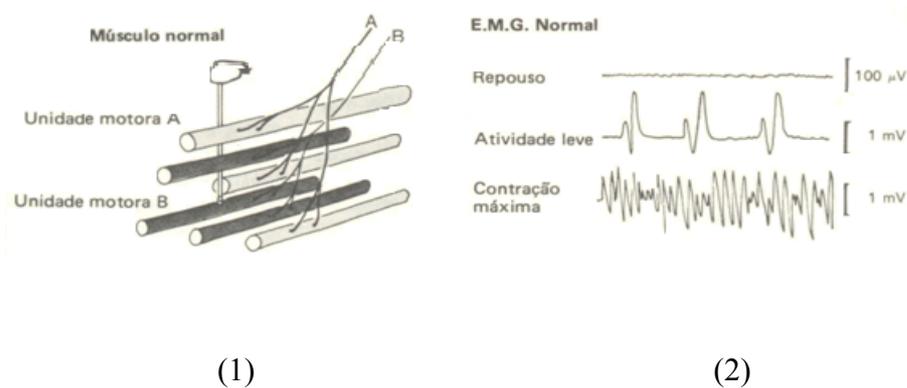


**Figura 1** Fibras musculares esqueléticas (adaptado de GUYTON, 2006).

A captação destes potenciais de ação muscular é realizada por eletrodos de superfície ou de agulha que captam a resultante desses campos eletromagnéticos denominado de Sinal Mioelétrico. Assim o Sinal Mioelétrico é formado através do somatório dos MUAPTs (*Motor*

*Unit Action Potential Train*), que é uma sequência de MUAPs provenientes dos potenciais de ação dos neurônios motores (BASMAJIAN & DE LUCA, 1985).

A contração voluntária mínima produz potenciais de ação de unidades motoras individuais. A descarga assíncrona de muitas fibras musculares cria o aumento da contração voluntária gerando padrões completos de interferência. As mudanças de tensão elétrica são muito pequenas, quando diferenças de potencial elétrico são captadas em resposta a atividade muscular. Eletrodos de superfície normalmente são capazes de captar sinais até 500 Hz com amplitudes máximas de 10 mV. Entretanto as amplitudes máximas encontradas na maioria das aplicações ficam próximas a 5 mV. A visualização adequada das respostas requer algum processamento do sinal por dispositivos eletrônicos, tais como amplificadores, filtros e conversores analógico-digitais. Na Figura 2, pode-se observar as fibras musculares ligadas aos axônios de dois neurônios A e B formando unidades motoras A e B, a forma de onda e o valor aproximado de tensão elétrica do SME adquirido quando o músculo está em repouso, executando atividade leve e em contração voluntária máxima e ainda, os valores de tensão de cada atividade (PATTEN, 2000).



**Figura 2 Unidade motora e EMG: (1) fibras musculares ligadas aos neurônios formando unidades motoras e (2) EMG com seus respectivos valores de tensão elétrica (Adaptado de PATTEN, 2000).**

## 2.2 IMPULSO NERVOSO OU POTENCIAL DE AÇÃO NERVOSO

Os neurônios possuem uma capacidade altamente desenvolvida de produzir e conduzir mensagens elétricas denominadas impulsos nervosos (potencial de ação nervoso). Esses impulsos apresentam-se como pequenas correntes elétricas que passam ao longo dos neurônios ou como movimentos de íons (partículas eletricamente carregadas) entre as superfícies externa e interna da membrana do neurônio. Essa corrente elétrica carrega informações de uma para outra parte do corpo ( GUYTON, 2006; TORTORA, 2000).

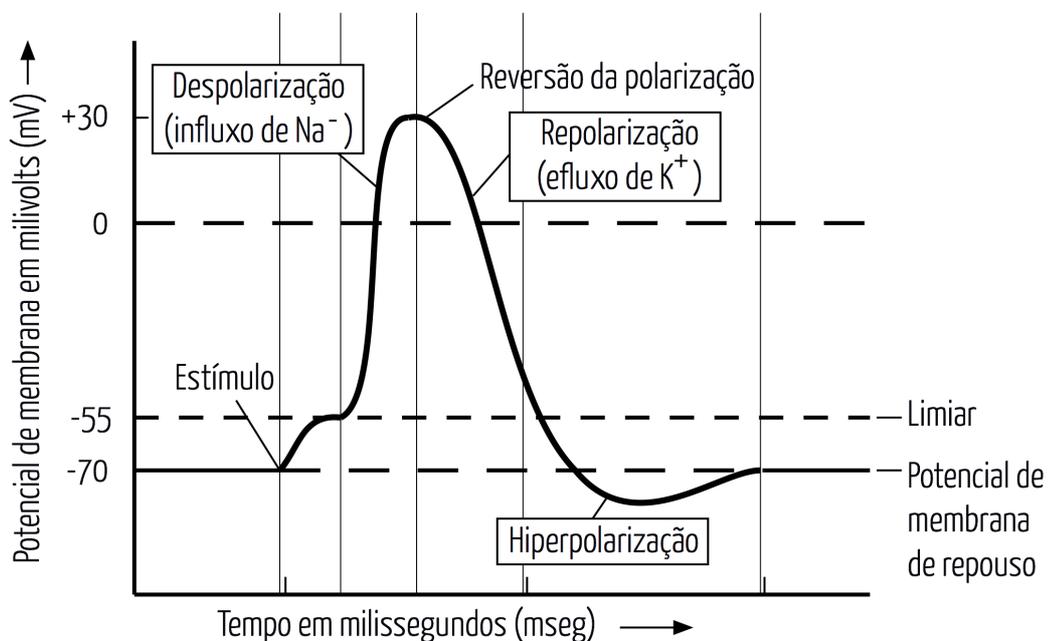
O ponto de encontro entre dois neurônios ou entre um neurônio e a célula muscular é chamado de sinapse. Existe somente a condução de impulso nervoso em uma única direção, onde não há contato físico. Os impulsos são transmitidos de um neurônio para o outro ou para a célula muscular por meio dos neurotransmissores, mediadores químicos liberados neste espaço. Essas substâncias são encontradas em vesículas próximas às sinapses (GUYTON, 2006; PATTEN, 2000; TORTORA, 2000).

A chegada do sinal elétrico na terminação nervosa pré-sináptica leva a liberação do neurotransmissor na fenda sináptica. O neurotransmissor atinge os receptores da membrana pós-sináptica ou da membrana da célula, despolarizando-a e alterando a permeabilidade aos diferentes íons. Com isso ocorre a passagem do impulso entre as fibras nervosas ou entre estas e as células (FAVIEIRO, 2012; GUYTON, 2006; TORTORA, 2000).

A Figura 3 apresenta o registro de alteração de potencial de um impulso nervoso. O potencial de ação se inicia com uma etapa de despolarização, seguida da repolarização e hiperpolarização.

Uma membrana é considerada polarizada ou em repouso quando é positiva no lado de fora e negativa no lado de dentro. Um estímulo é qualquer variação nas circunstâncias ambientais com capacidade adequada, atingindo um *threshold* (limiar), de alterar o potencial

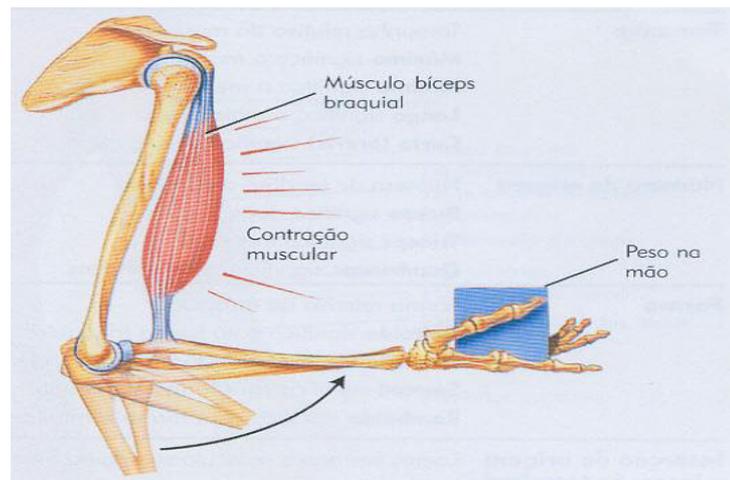
da membrana. A despolarização é a etapa, em que a membrana torna-se extremamente permeável aos íons positivos ( $Na^+$ ), ocorre, portanto aumento de carga positiva no interior da célula. A repolarização é a recuperação do potencial de membrana de repouso. Juntas, a despolarização e a repolarização, constituem um impulso nervoso. Durante a repolarização, o fluxo de saída de íons ( $K^+$ ) pode ser tão grande que ocorre a chamada hiperpolarização. A medida que os canais de íons ( $K^+$ ) fecham-se, o potencial da membrana retorna ao nível de repouso (GUYTON, 2006; TORTORA, 2000).



**Figura 3** Registro de alteração de potencial de um impulso nervoso (Adaptado de TORTORA, 2000).

### 2.3 CONTRAÇÃO E RELAXAMENTO DOS MÚSCULOS

Segundo Tortora (2000), o corpo é movido pela contração e o relaxamento dos músculos. A Figura 4 apresenta, como exemplo, a contração muscular do músculo Bíceps Braquial no movimento do antebraço erguendo um peso.

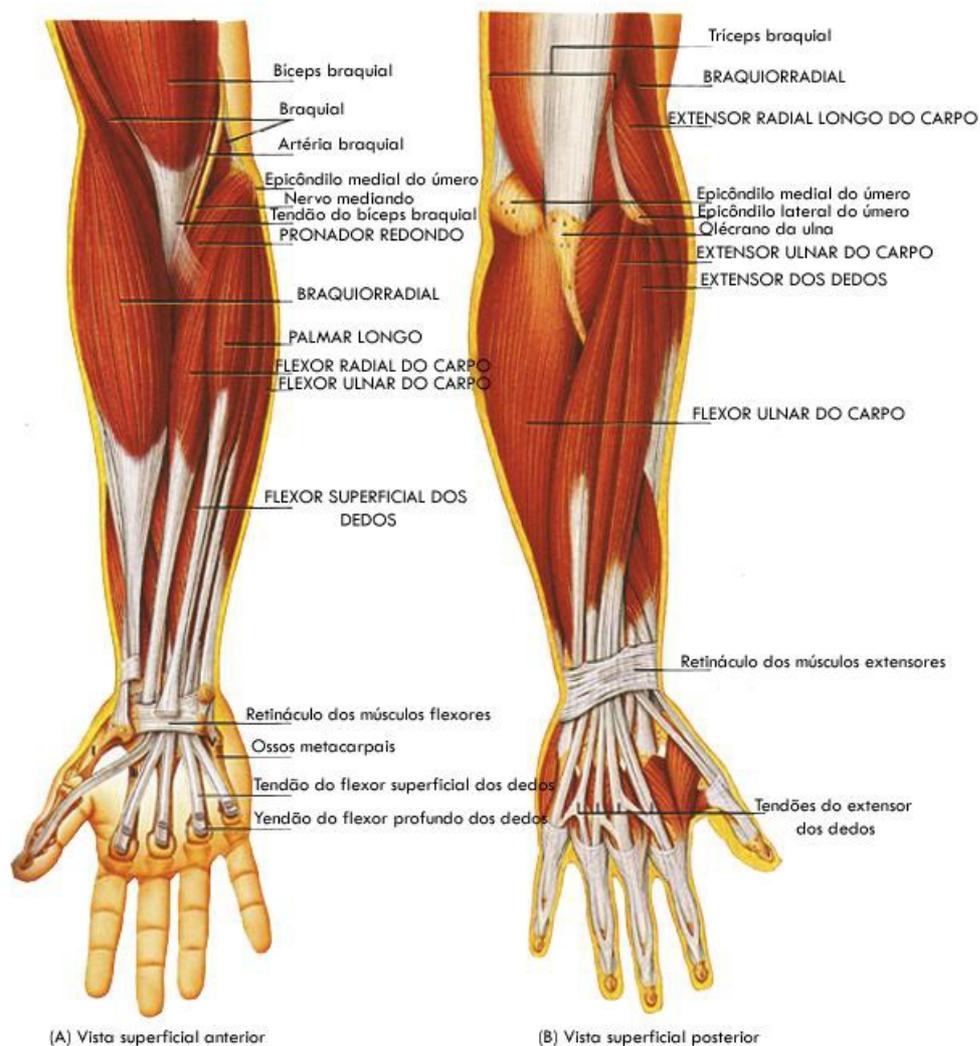


**Figura 4 Movimento do antebraço erguendo um peso (adaptado de TORTORA, 2000).**

O tecido muscular é composto de células extremamente desenvolvidas que realizam a contração e o relaxamento, que é a principal característica dos músculos. As células musculares são altamente especializadas, aptas a receber e a responder a estímulos, capazes de encurtar-se e contrair-se, além de distender-se e de retornar a sua forma original após a contração ou extensão. Possuem nervos e vasos sanguíneos que auxiliam na contração, no movimento de substâncias dentro do corpo, na estabilização do corpo e na regulação do volume dos órgãos. Para uma fibra muscular esquelética se contrair, ela deve ser estimulada por um impulso nervoso (potencial de ação muscular), necessitando de nutrientes e de oxigênio, e eliminando resíduos destas reações de produção de energia. Dentre todas as células do corpo humano, somente as células musculares e as células nervosas produzem impulso nervoso (PATTEN, 2000; TORTORA, 2000).

O movimento depende do funcionamento conjunto de ossos, articulações e músculos. Dentre os vários movimentos que podem ser realizados pelo corpo, citam-se apenas os relacionados a este estudo, tais como, flexão, extensão, abdução, adução, rotação, elevação, pronação e supinação. Enquanto a flexão diminui o ângulo em uma articulação, a extensão aumenta o ângulo. A abdução refere-se ao movimento para longe da linha mediana do corpo.

A pronação (rotação do antebraço) refere-se ao movimento da palma da mão para trás, já a supinação (rotação do antebraço) refere-se ao movimento da palma da mão para frente. Cada músculo é responsável por um ou mais tipos de movimentos. Com a Figura 5 pode-se verificar a localização dos principais músculos superficiais do braço e antebraço e com a Tabela 1 as suas funções (FAVIEIRO, 2012; SOBOTTA,1993; TORTORA, 2000).



**Figura 5 Principais músculos superficiais do braço e antebraço (TORTORA, 2000).**

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

MÚSCULO	AÇÃO
Bíceps Braquial	Flete e supina o antebraço; flexiona o braço.
Braquial	Flete o antebraço.
Pronador Redondo	Pronação do antebraço e da mão.
Braquiorradial	Flete o antebraço.
Palmar Longo	Flexiona a mão.
Flexor Radial do Carpo	Flete e abduz a mão.
Flexor Ulnar do Carpo	Flete e aduz a mão.
Flexor Superficial dos Dedos	Flete as falanges médias de cada dedo.
Extensor Radial do Carpo	Estende e abduz a mão.
Extensor Ulnar do Carpo	Estende e aduz a mão.
Extensor dos Dedos	Estende as falanges.

Fonte: Adaptado de TORTORA, 2000.

## 2.4 MÁQUINAS DE VETORES DE SUPORTE (SVM)

A Máquina de Vetores de Suporte é uma técnica de aprendizagem supervisionada, que se estabeleceu embasada na Teoria de Aprendizado Estatístico proposta por Vapnik (BOER, GUYON e VAPNIK, 1992; CORTES e VAPNIK, 1995; VAPNIK, 1995, 1998), empregada com destaque na classificação de padrões e regressão linear, tendo sua ênfase na capacidade de generalização. Esta capacidade é medida por sua eficiência na classificação de dados que não pertençam ao conjunto utilizado em seu treinamento. A capacidade de generalização evita o *overfitting*, situação na qual o classificador apresenta baixo desempenho quando

confrontado com novos padrões (CABENA, 1997; CAWLEY, 2006; ENGUEL, 2013; HAYKIN, 2001; LORENA & CARVALHO, 2003; SHAWE-TAYLOR & CRISTIANINI, 2000).

A seguir são apresentados alguns conceitos básicos importantes para facilitar a compreensão das Máquinas de Vetores de Suporte em problemas de classificação. Estes conceitos estão relacionados principalmente com o hiperplano de separação, com as funções *kernel* e com classificadores com mais de duas classes (Multi-Classes).

#### 2.4.1 Hiperplano de Separação

A Máquina de Vetores de Suporte (SVM) é usada para classificar dados em dois grupos através da construção de um hiperplano de separação, que atua como superfície de decisão de forma que as distâncias entre os grupos e o hiperplano sejam máximas. Podem existir vários hiperplanos capazes de separar os pontos de classes distintas em um espaço de alta dimensão, entretanto apenas um dos hiperplanos será ótimo, ou seja, terá sua distância maximizada dos exemplos de cada uma das classes (CHAGAS, 2009; ENGUEL, 2013; HAYKIN, 2001; SHAWE-TAYLOR & CRISTIANINI, 2000).

O Problema de otimização é encontrar o melhor hiperplano separador. O hiperplano é obtido na fase de treinamento da SVM, através de um conjunto de amostras composto por dois grupos separáveis, para construí-lo é necessário levar em conta uma pequena quantidade dos dados de treinamento os chamados vetores de suporte, como exemplo, pode-se ver estes pontos e o hiperplano ótimo na Figura 6. As linhas desenhadas paralelamente à linha tracejada de separação marcam a margem. Os vetores (pontos) que limitam a largura da margem são os vetores de suporte. Os vetores de suporte são os pontos mais próximos da superfície de

decisão, sendo os dados de treinamento mais difíceis de serem classificados. Os pontos além da margem não influenciam decisivamente na determinação do hiperplano, enquanto que os vetores de suporte, por terem pesos não nulos, são decisivos. A capacidade de generalização é grande se o hiperplano puder ser construído por um número pequeno de vetores de suporte (CHAGAS, 2009; ENGUEL, 2013; HAYKIN, 2001; LORENA & CARVALHO, 2003; SHAWE-TAYLOR & CRISTIANINI, 2000).

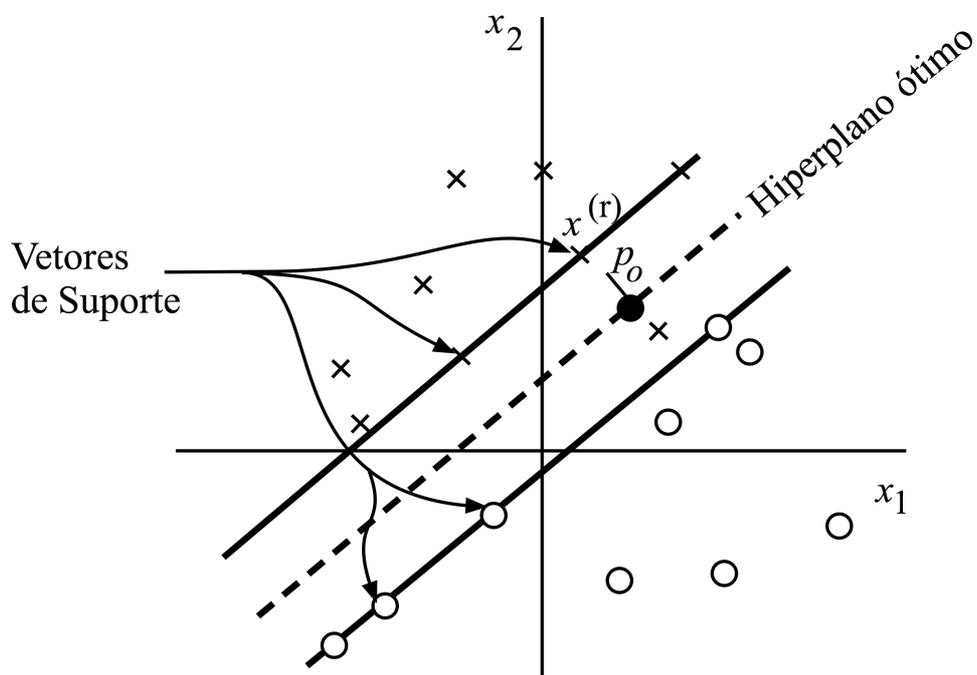


Figura 6 Vetores de Suporte e Hiperplano Ótimo (HAYKIN, 2001).

Segundo Haykin (2001) e Shawe-Taylor & Cristianini (2000), dada a amostra de treinamento separável

$$\mathfrak{S} = \{(\mathbf{x}_i, d_i)\}_{i=1, N} \quad (1)$$

onde  $\mathbf{x}_i$  é o padrão de entrada para o  $i$ -ésimo exemplo e  $d_i$  é a resposta desejada. As classes representadas pelo subconjunto  $d_i = +1$  e  $d_i = -1$  podem ser linearmente separáveis ou padrões não-separáveis.

### 2.4.1.1 Linearmente Separáveis

A equação de uma superfície de decisão, na forma de um hiperplano ótimo, é definida pela Equação (2).

$$w_0^T \mathbf{x} + b_0 = 0 \quad (2)$$

onde  $w_0$  e  $b_0$  representam os valores ótimos do vetor de peso ( $w$ ) e viés ( $b$ ) para determinado padrão de entrada ( $x$ ).

A medida algébrica da distância do padrão de entrada ( $x$ ) até o hiperplano é fornecida pela Equação (3), função discriminante. Expressando em função de  $x$  tem-se a Equação (4).

$$g(x) = w_0^T \mathbf{x} + b_0 \quad (3)$$

$$\mathbf{x} = \mathbf{x}_p + r \frac{w_0}{\|w_0\|} \quad (4)$$

onde  $\mathbf{x}_p$  é a projeção normal de  $x$  sobre o hiperplano ótimo e  $r$  é a distância algébrica desejada ( $r$  é positivo se  $x$  estiver no lado positivo do hiperplano ótimo e negativo se  $x$  estiver no lado negativo).

Considerando  $g(\mathbf{x}_p) = 0$ , por definição, chega-se a Equação (5)

$$g(x) = w_0^T \mathbf{x} + b_0 = r \|w_0\| \quad (5)$$

Logo, na Equação (6) tem-se a distância algébrica desejada ( $r$ ).

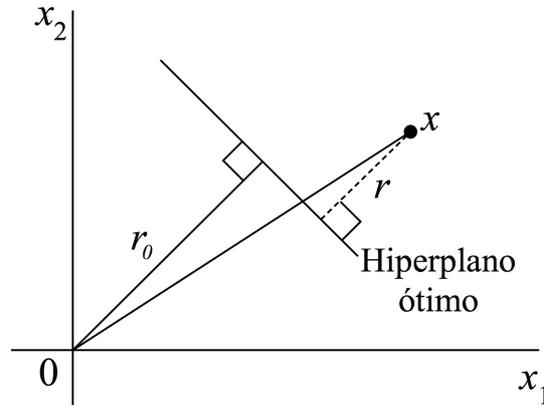
$$r = \frac{g(x)}{\|w_0\|} \quad (6)$$

A Equação (7) apresenta a distância da origem ( $x=0$ ) até o hiperplano ótimo.

$$r_0 = \frac{b_0}{\|w_0\|} \quad (7)$$

Assim, para  $b_0 > 0$  a origem fica no lado positivo do hiperplano ótimo, caso contrário, no lado negativo. Para  $b_0 = 0$  o hiperplano ótimo passa pela origem.

Na Figura 7 encontra-se a interpretação geométrica das distâncias algébricas de pontos até o hiperplano ótimo para um caso bidimensional.



**Figura 7 Interpretação geométrica das distâncias algébricas de pontos até o Hiperplano Ótimo (Adaptado de HAYKIN, 2001).**

As Equações (8) e (9) estabelecem a restrição para os parâmetros  $w_0$  e  $b_0$  para obtermos o hiperplano ótimo e os vetores de suporte, que limitam a largura da margem.

$$w_0^T x_i + b_0 = 1 \quad (8)$$

$$w_0^T x_i + b_0 = -1 \quad (9)$$

Os pontos de dados além da margem não influenciam decisivamente na determinação do hiperplano e são definidos pelas Equações (10) e (11).

$$w_0^T x_i + b_0 \geq 1 \quad (10)$$

$$w_0^T x_i + b_0 \leq -1 \quad (11)$$

Com base nas Equações (6) e (8) a distância algébrica dos vetores de suporte até o hiperplano ótimo ficará definida segundo a Equação (12) e (13).

$$r = \frac{g(x)}{\|w_0\|} = \frac{1}{\|w_0\|} \text{ se } d = +1 \quad (12)$$

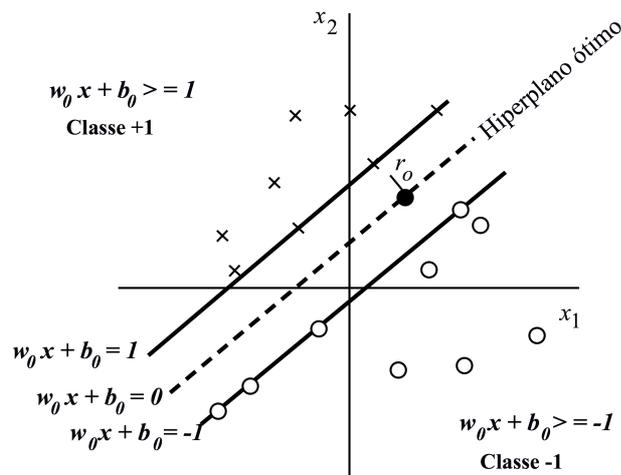
$$r = \frac{g(x)}{\|w_0\|} = \frac{-1}{\|w_0\|} \text{ se } d = -1 \quad (13)$$

A Equação (14) apresenta o valor ótimo da margem de separação ( $\rho$ ) entre as duas classes.

$$\rho = 2r = 2 \frac{1}{\|w_0\|} = \frac{2}{\|w_0\|} \quad (14)$$

O vetor peso ( $w_0$ ) fornece a máxima separação possível entre exemplos positivos e negativos. Maximizar  $\rho$  é equivalente a minimizar a normal euclidiana do vetor peso  $w$ .

A Figura 8 apresenta o hiperplano ótimo de duas classes distintas +1 e -1, com a equação de uma superfície de decisão, as equações dos vetores de suporte - que se localizam próximos à superfície de decisão - e as equações dos demais pontos, que não influenciam na determinação do hiperplano ótimo.



**Figura 8 Hiperplano Ótimo com classes distintas e as equações (Adaptado de HAYKIN, 2001).**

O objetivo da otimização é encontrar os valores ótimos do vetor peso e bias que satisfaçam as restrições das Equações (10) e (11) e minimize a função de custo ( $\Phi$ ) definida pela Equação (15).

$$\Phi(w) = \frac{1}{2} w^T w \quad (15)$$

### 2.4.1.2 Padrões Não-Separáveis

Com classes (padrões) não-separáveis haverá erros de classificação ao construir o hiperplano de separação, por isso deve-se encontrar um hiperplano ótimo que minimize esta probabilidade.

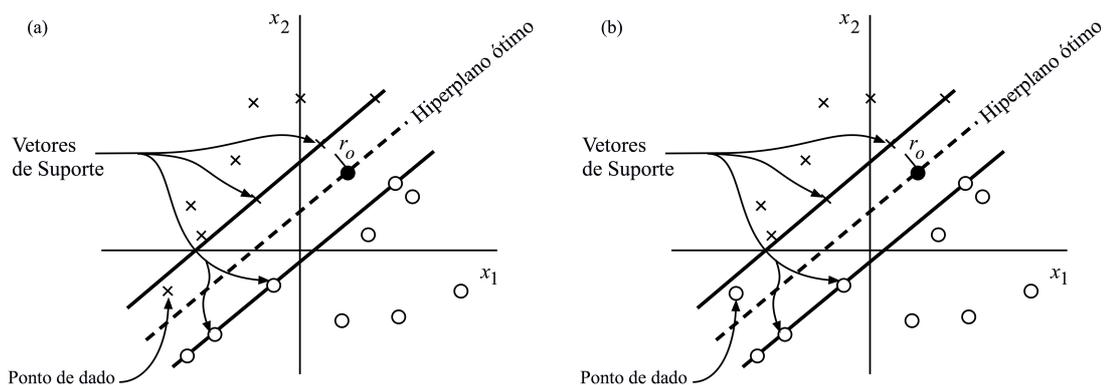
Se um ponto de dados ( $\mathbf{x}_i, d_i$ ) desobedecer a condição definida pela Equação (16) e se encontrar do lado errado da superfície de decisão teremos uma classificação incorreta.

$$d_i (w^T \mathbf{x}_i + b) \geq 1 \quad (16)$$

As variáveis *slack* ( $\xi_i$ ), não-negativas  $\xi_i \geq 0, i = 1, \dots, N$ , medem o desvio de um dado  $i$  em relação à condição de separação. Logo, as restrições da margem de separação de um hiperplano ficam de acordo com a Equação (17):

$$d_i (w\mathbf{x}_i + b) \geq 1 - \xi_i, i = 1, \dots, N \quad (17)$$

A Figura 9 apresenta as variáveis de folga (*slack*) quando,  $0 \leq \xi_i \leq 1$ , o ponto de dado está dentro da região de separação, mas no lado correto da superfície de decisão. Quando,  $\xi_i > 1$ , o ponto de dado se encontra do lado errado.



**Figura 9 (a) O ponto de dado se encontra dentro da região de separação e no lado correto. (b) O ponto de dado se encontra do lado errado da superfície de decisão (HAYKIN, 2001).**

Os vetores de suporte são aqueles pontos que satisfazem a igualdade, mesmo que  $\xi_i > 0$ . Se um ponto com  $\xi_i > 0$  ficar fora do conjunto de treinamento a superfície de decisão não

muda. Logo, os vetores de suporte são definidos do mesmo modo tanto para padrões linearmente separáveis como não-separáveis.

Para encontrar um hiperplano de separação onde o erro de classificação é minimizado, pode-se minimizar a função de custo ( $\Phi$ ) em relação às variáveis de *slack* ( $\xi$ ) definida pela Equação (18).

$$\Phi(\xi) = \sum_{i=1}^N \xi_i \quad (18)$$

A Equação (19) apresenta a formulação da função de custo  $\Phi(w, \xi)$

$$\Phi(w, \xi) = \frac{1}{2} w^T w + C \sum_{i=1}^N \xi_i \quad (19)$$

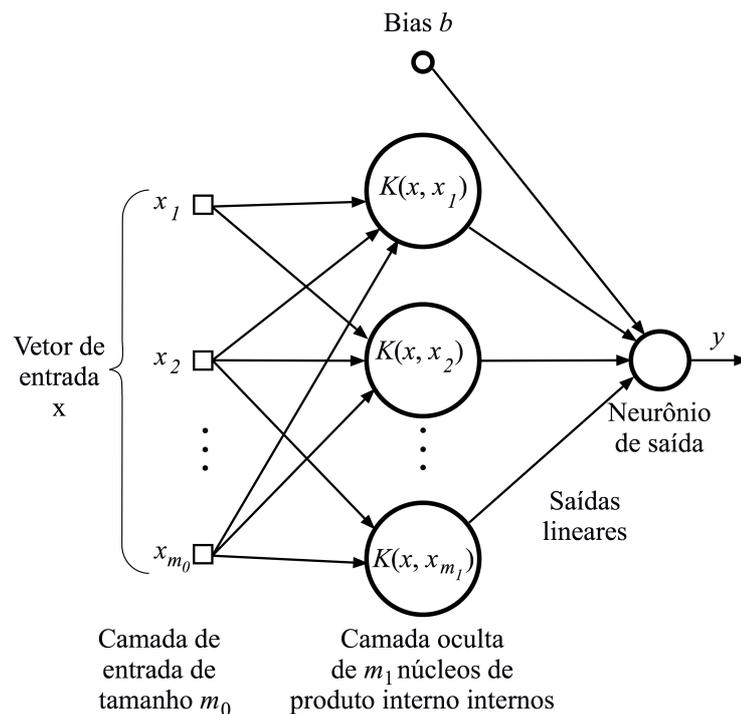
A minimização do primeiro termo está relacionada com os pesos, e em consequência a margem de separação das classes, definida pela Equação (14). O segundo termo da função de custo ( $\sum_{i=1}^N \xi_i$ ) é um limite para o número de erros de teste. O  $C$  é um parâmetro de regularização da SVM, ou parâmetro de custo, especificado pelo usuário que determina a precisão do modelo. Aumentando o valor de  $C$  aumenta o custo e obriga a criação de um modelo mais preciso que não pode generalizar bem. Ele controla a complexidade da máquina e o número de pontos não separáveis (CHAGAS, 2009; HAYKIN, 2001; SHAWE-TAYLOR & CRISTIANINI, 2000).

#### 2.4.2 Função *Kernel*

A função *kernel* (núcleo de produto interno) é uma técnica matemática que permite a SVM separar linearmente as amostras pertencentes a diferentes classes, sem que estas sejam linearmente separáveis em sua dimensão original. Dependendo de como este núcleo de produto interno é gerado, pode-se construir diferentes máquinas de aprendizagem, caracterizadas por superfícies de decisão não-lineares. Muitas funções de mapeamento do

*kernel* podem ser usadas, algumas (polinomial, sigmóide e função de base radial) funcionam bem para uma vasta variedade de aplicações. O padrão recomendado é a função de base radial (CHAGAS, 2009; ENGUEL, 2013; HAYKIN, 2001; LORENA & CARVALHO, 2003; SHAWE-TAYLOR & CRISTIANINI, 2000).

A Figura 10 apresenta a arquitetura de uma SVM não linear que é formada por uma camada de entrada para distribuir o sinal de entrada, uma camada oculta, composta de nós que implementam núcleos de produtos internos não-lineares que realizam o mapeamento não-linear do espaço de entrada para um espaço de características, e uma camada de saída com um nó linear (HAYKIN).



**Figura 10 Arquitetura de uma SVM não linear (HAYKIN, 2001).**

A função *kernel* ( $K$ ) faz o mapeamento do espaço de entrada para um espaço de características. No espaço de características, os pontos pertencentes a diferentes classes podem ser linearmente separáveis pelo hiperplano. Esta é a capacidade altamente especializada do funcionamento da SVM, utilizar uma função *kernel* capaz de mapear os

dados a partir do seu espaço original em um espaço onde seja possível separar linearmente os pontos pertencentes a diferentes classes. A escolha da função *kernel* é um parâmetro a ser determinado na implementação da SVM, ajustando-se a função *kernel* que apresenta os melhores resultados em um dado problema (CHAGAS, 2009; ENGUEL, 2013; HAYKIN, 2001; LORENA & CARVALHO, 2003).

### 2.4.3 Classificação com mais de duas classes

A SVM é utilizada diretamente somente para casos em que houver duas classes (binário). Várias abordagens têm sido recomendadas para separar os vetores de características em casos onde há mais de duas classes (Multi-Classes). As mais populares são: um contra todos (*one-versus-all*) e, um contra um (*one-versus-one*) (CHAGAS, 2009; LORENA & CARVALHO, 2003).

Na SVM Multi-Classes um contra todos (*one-versus-all*) uma classe é distinguida e todas as outras são mescladas. Para cada classe é construído um classificador, ou seja, se existirem 5 classes são construídos 5 classificadores. A classificação é baseada na estratégia o-vencedor-ganha (*winner-takes-all*) (CHAGAS, 2009; LORENA & CARVALHO, 2003).

Na SVM Multi-Classes um contra um (*one-versus-one*)  $k(k-1) / 2$  modelos são construídos onde  $k$  é o número de classes, ou seja, se houver 5 classes, então são construídos 10 classificadores. A classificação é determinada por uma estratégia de votação que a maioria vence (*max-wins voting*). A técnica mais precisa é a um contra um, mas computacionalmente mais custosa (CHAGAS, 2009; LORENA & CARVALHO, 2003).

## 2.5 OUTROS TRABALHOS QUE UTILIZARAM EMG PARA CARACTERIZAR O MOVIMENTO DO SEGMENTO MÃO-BRAÇO

Diversos trabalhos, nos últimos anos, foram desenvolvidos utilizando EMG para caracterizar movimentos de segmentos do corpo humano. Esses trabalhos apresentam diferenciação nas técnicas de segmentação do sinal de interesse, no tipo de classificador utilizado, no tipo e número de características e no tipo de membro do corpo humano avaliado, assim como, no objetivo final de cada estudo, como por exemplo, monitoramento de fadiga muscular, caracterização de desordens musculares, uso do biosinal para gerenciar dispositivos, etc. Isso evidencia a dificuldade de comparar determinados trabalhos com outros e a importância de estudos continuados nesta área.

KAUR, ARORA & JAIN, 2009, fizeram a comparação entre três técnicas utilizadas para segmentação de sinais EMG:

- a) segmentação identificando os picos da MUAPs,
- b) segmentação encontrando o *Beginning Extraction Point* (BEP) e *Ending Extraction Point* (EEP) de MUAPs
- c) e segmentação usando *Discrete Wavelet Transform* (DWT).

A taxa de acerto da técnica utilizada para extrair picos MUAPs foi de 95,0%. Para a técnica de BEP e EEP foi de 75,4% e para a técnica DWT, de 66,6%.

FAVIERO & BALBINOT, 2009 utilizaram oito canais de aquisição do Sinal Mioelétrico. A técnica utilizada para caracterização de determinados movimentos foi a Neuro-Fuzzy e verificaram a validade em termos de desempenho. As séries executadas foram caracterizadas em 12 movimentos distintos, previamente definidos, com uma taxa de acerto médio de 65%.

BERMUDEZ, 2013 utilizou oito canais de aquisição do Sinal Mioelétrico e realizou o processamento do Sinal Mioelétrico através de Redes Neurais para analisar o desempenho do sistema. Ao final dos testes, constatou que o movimento de contração da mão e elevação do braço apresentou uma taxa de acerto média de 75%; o movimento de flexão do antebraço obteve 81% de acerto médio; a contração da mão, 33% de acerto médio; o movimento contração da mão, 76% de acerto médio; o movimento de flexão do punho, 100 % de acerto; rotação e flexão do antebraço, 66% de acerto médio; extensão e flexão do punho, 16% de acerto médio; extensão do punho, 83,3% de acerto médio; rotação do braço, 16,7% de acerto médio; rotação do braço e contração da mão, 83,3% de acerto médio.

BOSCHMANN, KAUFMANN e PLATZNER, 2009 consideram a SVM um poderoso classificador. Utilizaram quatro pares de eletrodos dispostos no antebraço para caracterizar uma sequência de 11 diferentes movimentos, obtendo um reconhecimento médio de 91,3% em mais de 11 movimentos e, em mais de quatro movimentos, de 100%. Segundo LIU, HUANG & LIU, 2010 a precisão da classificação da SVM é significativamente melhor do que o classificador de rede neural RBF. Dessa forma propôs quatro tipos de abordagens de classificação multiclasse para a classificação de padrões EMG, e obteve resultados experimentais com taxa de reconhecimento superior a 90%.

Em 2012, ATZORI, GIJSBERTS, HEYNEN *et al.* construíram uma base de dados chamada banco de dados NINAPRO com o objetivo de melhorar o estado da arte em EMG a fim de estabelecer um padrão, amplamente aceito como referência na coleta de um número elevado de posturas da mão, com vários voluntários, tanto intactos como amputados. Uma ferramenta para a comunidade que estuda biorrobótica, especialmente para aqueles preocupados com o controle de Sinais Mioelétricos das próteses de mão. A análise preliminar do banco de dados foi realizada através do processamento baseado em SVM. Após a

realização do processamento padrão, revelou-se que os dados são perfeitamente utilizáveis e as taxas de erros são comparáveis aos encontrados na literatura. É importante ressaltar que a base de dados NINAPRO não foi utilizada neste trabalho, pois os movimentos avaliados que utilizei são mais complexos. As Tabelas 2, 3 e 4 apresentam o resumo de alguns trabalhos de investigação científica realizados com a eletromiografia.

**Tabela 2 Os resultados de outros estudos. (Adaptado de BALBINOT, FAVIEIRO, 2013)**

<b>Estudo Selecionado</b>	<b>Ahsan et al.</b>	<b>Rajesh et al.</b>	<b>George et al.</b>	<b>Shenoy et al.</b>
Movimentos utilizados	Esquerda, direita, acima, abaixo	Extensão da mão, contração da mão, extensão do punho, flexão do punho, pinça e flexão do polegar	Classificação das diferentes velocidades do movimento do cotovelo	Gesto estático da mão (gestos correspondem a pares de ações: aperto-liberação, esquerda-direita, de cima para baixo e girar)
Características	Valor médio absoluto, RMS, variância, desvio padrão, zero <i>crossing</i> , <i>slope sign change</i> e <i>Wilson amplitude</i>	Entropia, RMS e desvio padrão	Valor médio absoluto e variância	RMS
Classificações	Rede neural artificial	Distância euclidiana	Classificador de lógica Fuzzy (FLC) e classificador probabilístico de rede neural (PNNC)	Máquina de Vetores de Suporte linear
Taxa de acertos média	88,4%	RMS: 83,3%	97,3% para FLC e 93.6% para PNNC	92% a 98%

Tabela 3 Os resultados de outros estudos. (Adaptado de BALBINOT, FAVIEIRO, 2013)

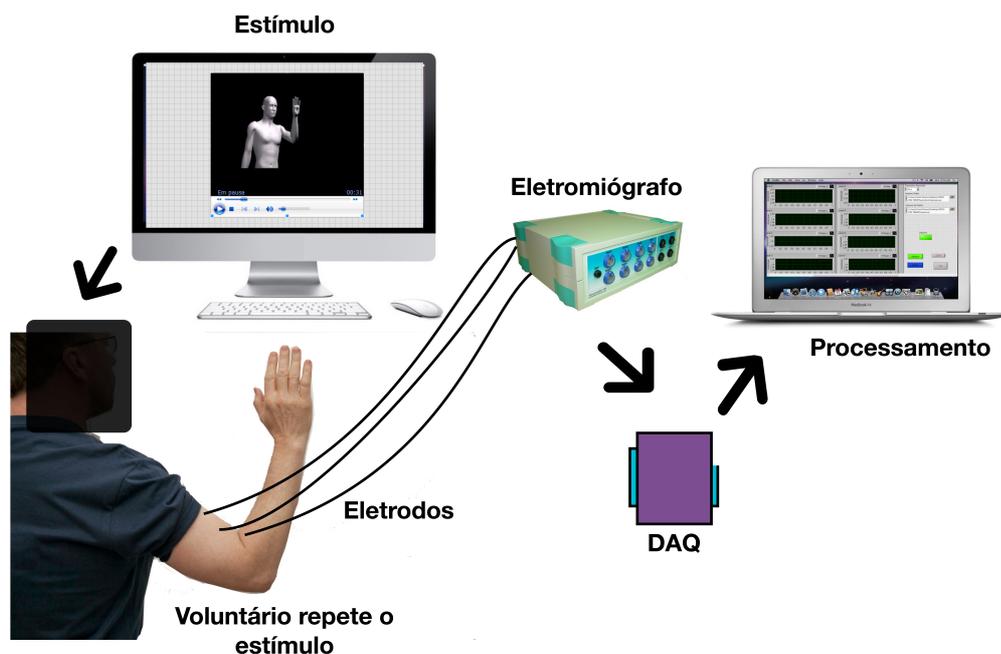
Estudo Selecionado	Kurzynski et al.	Khezri et al.	Khezri et al.	Boschmann et al.
Movimentos utilizados	7 ações elementares foram distinguidas no processo de aperto com a mão. Posição de descanso, preparação de aperto, encerramento de aperto, pegada, mantendo o aperto, liberando aperto, transição para a posição de repouso	8 movimentos da mão: abertura e fechamento da mão, apertar, flexão polegar, flexão e extensão radial do pulso e flexão e extensão do pulso	Comandos de movimento de mão (abertura e fechamento da mão, pinça e flexão do polegar e flexão e extensão do punho), mas com <i>feedback</i> da visão para aumentar a capacidade do sistema	7 diferentes movimentos: flexão, extensão, desvio ulnar, desvio radial, pronação, supinação, abrir, fechar, pega chave, aperto pinça e extrair o dedo indicador
Características	6 tipos, dependendo do objeto à segurar (uma caneta, um cartão de crédito, um mouse de computador, um telefone celular, uma chaleira e um tubo)	Domínio do tempo, domínio tempo-frequência e sua combinação	Valor médio absoluto, <i>slope sign changes</i> e <i>AR model coefficients</i>	
Classificações	5 tipos: Abordagem Bayes com o modelo de Markov, perceptron de múltiplas camadas, multi classificador com a função de competência, classificador baseado em lógica fuzzy e classificador baseado na teoria de <i>Dempster-Shafer of evidence</i>	Sistema de inferência fuzzy (FIS) e redes neurais artificiais (RNA)	Sistema adaptativo de inferência neuro-fuzzy (ANFIS)	Máquina de Vetores de Suporte
Taxa de acertos média	Sistema de inferência Mamdani é aplicado com um <i>one-instant-backwards</i> e <i>two-instant-backwards dependence</i> (algoritmos FS1 e FS2): as precisões de classificação dos classificadores sequenciais comparados na experiência: para FS1: 72,5 (Ordem do Modelo AR era de 2) par 89,7 (Ordem do Modelo AR era de 8) e FS2: 69,5 (Ordem do Modelo AR era de 2) de para 88,5 (Ordem do Modelo AR era de 8)	Para oito movimentos foi de 83% e 78%	Os resultados médios do sistema neuro-fuzzy: Abertura - 98%; fechamento - 100%; flexão do punho - 94%; extensão do punho - 96%; pinça - 98%	De todos os 11 movimentos foi de 91,3%

Tabela 4 Os resultados de outros estudos. (Adaptado de BALBINOT, FAVIEIRO, 2013)

<b>Estudo Selecionado</b>	<b>Balbinot e Faviero (2013)</b>	<b>Bermudez</b>	<b>Este trabalho</b>
Movimentos utilizados	7 movimentos: flexão do punho; contração da mão, a extensão do punho, flexão do antebraço, rotação do antebraço, e adução e abdução da mão	9 movimentos: flexão do punho; contração da mão, extensão do punho, flexão do antebraço, rotação do braço, rotação e flexão do antebraço, rotação do braço e contração da mão, extensão e flexão do punho e contração da mão e elevação do braço	5 movimentos: flexão do punho; contração da mão, extensão do punho, flexão do antebraço, supinação do antebraço, rotação e flexão do antebraço, contração da mão, extensão e flexão do punho e contração da mão
Características	Valor RMS	Média, variância, desvio padrão, <i>skewness</i> , <i>kurtosis</i> , RMS	Média, variância, desvio padrão, <i>skewness</i> , <i>kurtosis</i> , RMS
Classificações	Neuro-Fuzzy	Redes Neurais	Máquina de Vetores de Suporte
Taxa de acertos média	86% e aproximadamente 90% (contração da mão, a extensão do punho, flexão do punho e abdução da mão)	63%	

### 3 METODOLOGIA EXPERIMENTAL

A Figura 11 apresenta o diagrama de blocos simplificado do sistema proposto neste trabalho. O sistema é constituído de eletrodos de superfície, colocados em pontos específicos do braço, para a aquisição do Sinal Mioelétrico, de um eletromiógrafo de oito canais, que realiza o condicionamento do sinal, de uma placa de conversão de dados da National Instruments (DAQ 6009) e de um computador responsável pelo processamento dos dados. Nos próximos sub-capítulos são apresentadas discussões completas de cada um desses blocos.



**Figura 11 Diagrama de blocos do sistema proposto.**

Os voluntários são informados da natureza dos procedimentos a que serão submetidos e orientados a assinar um Termo de Consentimento Livre e Esclarecido, contendo explicações e possíveis riscos que podem ocorrer. Este trabalho faz parte do projeto aprovado pelo Comitê de Ética CAAE: 11253312.8.0000.5347. No software *LabView*, foi desenvolvido um programa para executar vídeos (estímulos ou movimentos padrões) e para adquirir dados. Os

vídeos contém o modelo virtual que demonstra ao voluntário os movimentos do segmento mão-braço, que devem ser imitados. Ao realizar os movimentos seus sinais mioelétricos são obtidos com um eletromiógrafo de oito canais e um canal de referência posicionado na testa do voluntário. Este eletromiógrafo foi desenvolvido no projeto de pesquisa coordenado por BALBINOT, 2006. Do eletromiógrafo os Sinais Mioelétricos são enviados para a placa de conversão de dados (DAQ) para serem posteriormente processados no computador. A placa utilizada foi a NI USB 6009 da National Instruments, que apresenta oito canais de entrada analógica com resolução de 10 bits e taxa de amostragem de 10kS/s, tendo uma tensão de entrada máxima para os canais analógicos de  $\pm 10V$ , com taxa de aquisição de 1kHz por canal, a faixa de frequência de interesse é de, no máximo, 250Hz O *software Matlab* foi utilizado para realizar o pré-processamento e a caracterização dos movimentos. O classificador empregado foi “(L2) SVM Classification Toolbox”.

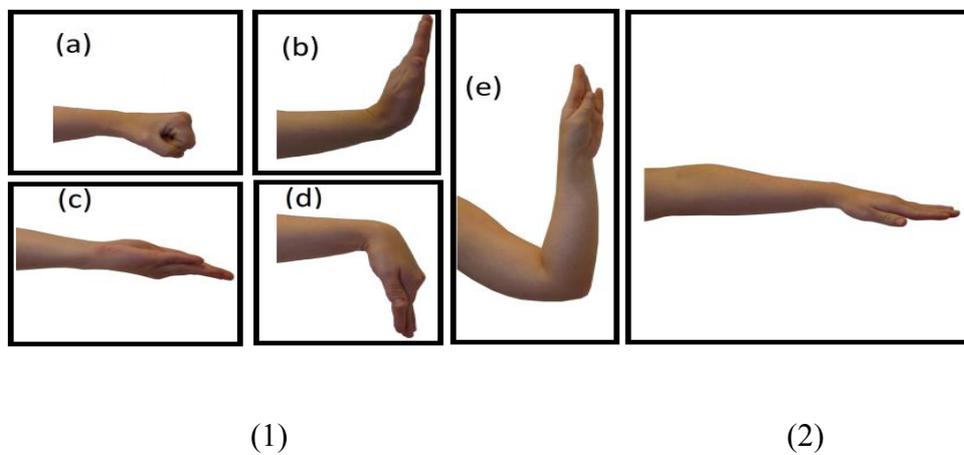
### 3.1 MODELO VIRTUAL

O modelo virtual foi criado com dois objetivos específicos, a saber, o voluntário precisa ter uma referência visual com o propósito de repetir os gestos pré-definidos do segmento mão-braço e possuir uma ideia do tempo de execução para cada movimento. Sendo assim, os movimentos virtuais são um padrão a ser seguido por todos os voluntários, obtendo, desta forma, os mesmos movimentos do segmento mão-braço para cada voluntário.

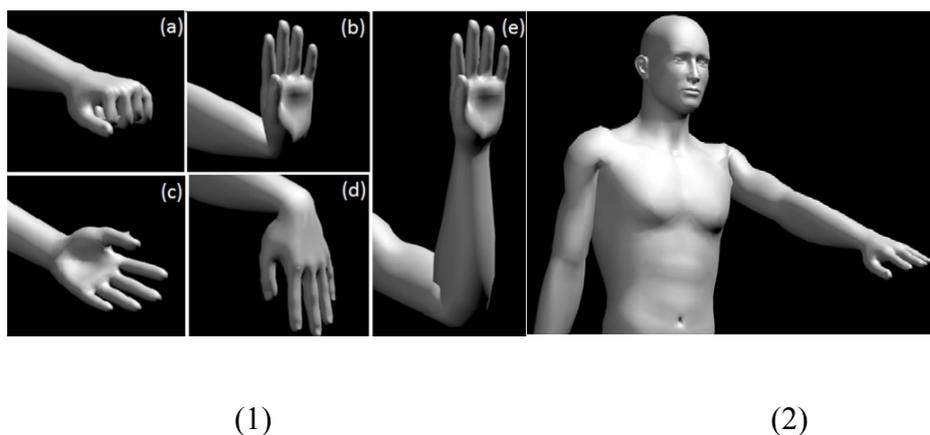
As animações que contém os movimentos simples e compostos do segmento mão-braço, foram criadas e desenvolvidas por CONTO & BALBINOT (2011), utilizando os softwares MakeHuman 1.0 Alpha5 e Blender 2.54 Beta. As séries de movimentos, que contém movimentos simples e compostos do segmento mão-braço, separados por intervalos de descanso, entre eles, foram elaboradas por BERMUDEZ (2013).

### 3.1.1 Movimentos Simples

A Figura 12 apresenta os cinco movimentos simples escolhidos e a posição de repouso, para formar a série de movimentos do segmento mão-braço do modelo virtual. Na Figura 13 encontram-se alguns detalhes do modelo virtual. Os movimentos simples escolhidos foram: Contração da Mão, Extensão do Punho, Rotação do Antebraço (Supinação), Flexão do Punho e Flexão do Antebraço.



**Figura 12** Fotos representando os movimentos simples: (1) zoom da mão: (a) contração da mão, (b) extensão do pulso, (c) supinação, (d) flexão do punho, (e) flexão do antebraço e (2) posição de repouso (Adaptado de FAVIEIRO, 2009).



**Figura 13** Modelo Virtual representado os movimentos simples: (1) zoom da mão: (a) contração da mão, (b) extensão do pulso, (c) supinação, (d) flexão do punho, (e) adução do punho, (f) abdução do punho, (g) flexão do antebraço e (2) posição de repouso. (FAVIEIRO, 2013).

### 3.1.2 Movimentos Compostos

Os movimentos compostos diferenciam-se por apresentar uma combinação dos movimentos simples definidos anteriormente (FAVIEIRO, 2012). Os cinco movimentos compostos selecionados foram: rotação do antebraço com flexão do antebraço, rotação do antebraço com contração da mão, extensão e flexão do punho, contração da mão e flexão do antebraço. A duração total para cada um dos movimentos compostos foi de aproximadamente 17 segundos.

### 3.1.3 Séries de Movimentos

As séries de movimentos do segmento mão braço, apresentadas pelo modelo virtual, são constituídas por movimentos simples e movimentos compostos intercalados por repouso. Todas as séries começam na posição de repouso, executam um dos movimentos simples ou compostos, citados anteriormente, e voltam ao repouso e assim, sucessivamente, totalizando um tempo de 250s. A Tabela 5 apresenta as sete séries usadas nos ensaios. Determinados movimentos podem ser repetidos para que o tempo total, de cada série, seja igual.

**Tabela 5 Séries com seus respectivos movimentos (Adaptado de BERMUDEZ, 2013).**

Série	Movimentos																	
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
A	RA	EFP	FA	RFA	EFP	FA	CM	FP	CM	CMF	RFA	RAC	RA	EP	FP	RAC	EP	CMF
B	EP	EFP	RAC	FA	RA	FA	RA	CMF	FP	EP	RFA	CMF	RAC	CM	CM	FP	RFA	EFP
C	CMF	FA	CM	RA	RA	CM	FA	EP	CMF	RFA	RAC	FP	FP	RFA	EFP	EP	EFP	RAC
D	FP	EP	RA	RAC	RA	RAC	FA	FP	FA	RA	RAC	FA	FP	EP	CM	FP	EFP	RFA
E	CM	CMF	RAC	RA	CMF	EP	RFA	EFP	FA	RA	RAC	FA	FP	EP	CM	FP	EFP	RFA
F	CMF	EFP	FA	EP	FA	RA	EP	CMF	RAC	CM	EFP	RAC	FP	RA	RFA	FP	RFA	CMF
G	EFP	RAC	RAC	FP	FA	EFP	CM	RFA	FA	EP	CM	RFA	CMF	RA	FP	CMF	EP	RA

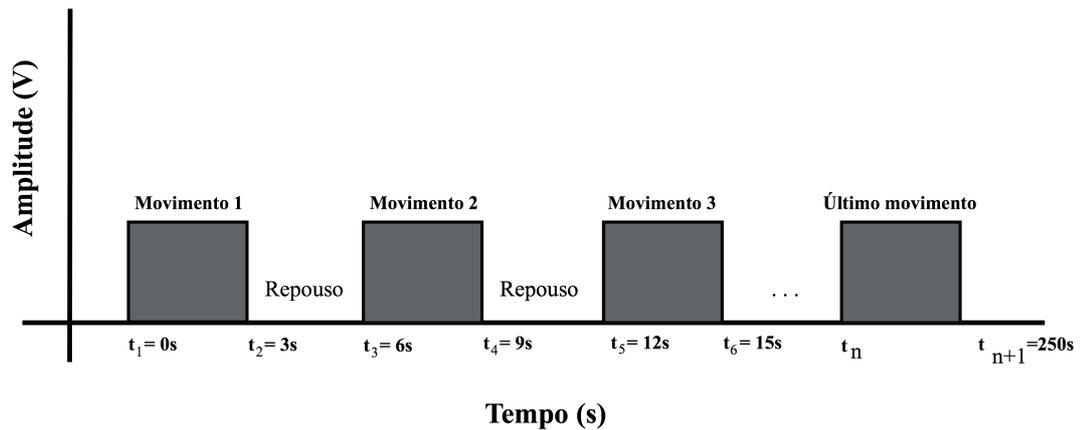
#### Legenda do Movimento

CM. Contração da Mão  
EP. Extensão do Punho  
FA. Flexão do Antebraço

FP. Flexão do Punho  
RA. Rotação do Antebraço  
RFA. Rotação/Flexão do Antebraço

RAC. Rotação do Antebraço e Contração da Mão  
EFP. Extensão e Flexão do Punho  
CMF. Contração da Mão e Flexão do Antebraço

A Figura 14 apresenta um exemplo de um das seqüências de movimentos executados nos vídeos. Cada série tem um total de 250s e os movimentos são intercalados por um repouso de 3s.

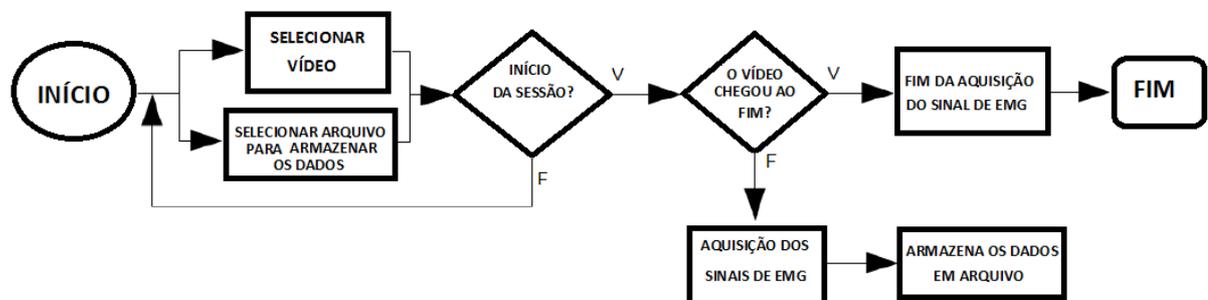


**Figura 14** Gráfico contendo a seqüência de movimentos (Adaptado de BERMUDEZ, 2013).

### 3.2 ROTINA PARA EXECUTAR VÍDEOS E ADQUIRIR DADOS

No software *LabView*, foi desenvolvido um programa para executar vídeos e adquirir dados. Os vídeos contém o modelo virtual que demonstra ao voluntário os movimentos do segmento mão-braço que devem ser imitados. Eles foram gravados usando o formato “.avi”. O programa faz a leitura de arquivos “.avi” e os apresenta na tela de vídeo para serem imitados pelo voluntário. A Figura 15 apresenta o fluxograma da rotina de execução de vídeos e de aquisição de dados. Na Figura 16, observa-se, no painel frontal do *LabView*, as animações que aparecerão na tela de vídeo e, no painel diagrama de blocos, parte da rotina desenvolvida para a visualização da seqüência aleatória de movimentos do modelo virtual. A rotina desenvolvida no *LabView* faz a leitura de arquivos “.avi” e o vídeo pode ser visualizado em uma janela do *Windows Media Player*. Um arquivo com formato “.avi” é lido através de

um caminho fixo fornecido (AVI Path) enviando o comando de abrir o Windows Media Player e de rodar o correspondente vídeo. A aquisição e a criação do banco de dados foram programadas para ler os dados de entrada, adquiridos da placa DAQ, e gravá-los em um arquivo com formato “.lvm”, através do VI DAQ *Assistant*. Na Figura 17, observa-se o painel frontal do *LabView* para aquisição de oito canais, que aparecerá na tela do computador para controle do operador e parte da rotina de aquisição de dados dos oito canais do painel diagrama de blocos.



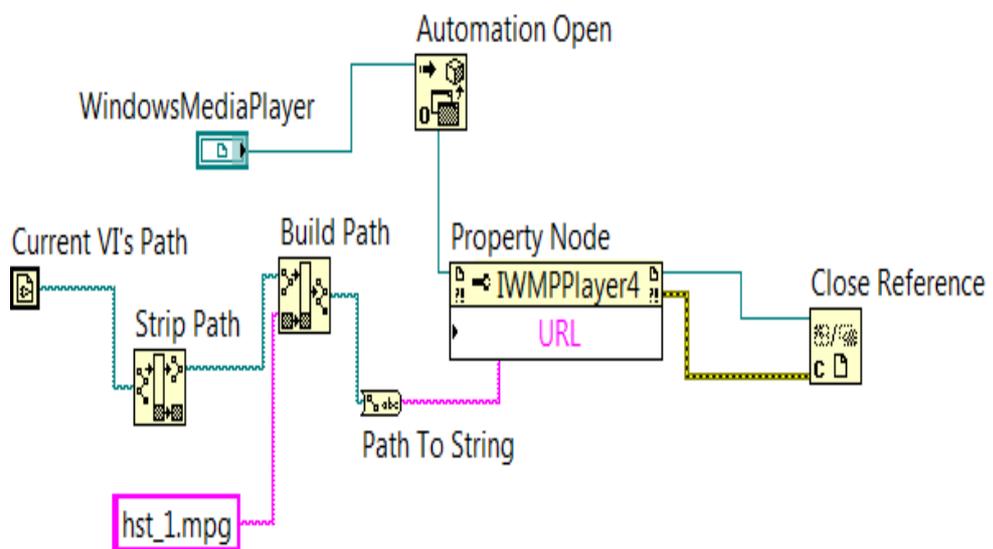
**Figura 15 Fluxograma da rotina de execução de vídeos e de aquisição de dados.**

Na Figura 18 observam-se, apenas como exemplo, dois canais dos Sinais Mioelétricos adquiridos em dois músculos: Bíceps e Flexor Ulnar do Carpo.

Na Figura 19 observam-se os Sinais Mioelétricos adquiridos em oito canais.

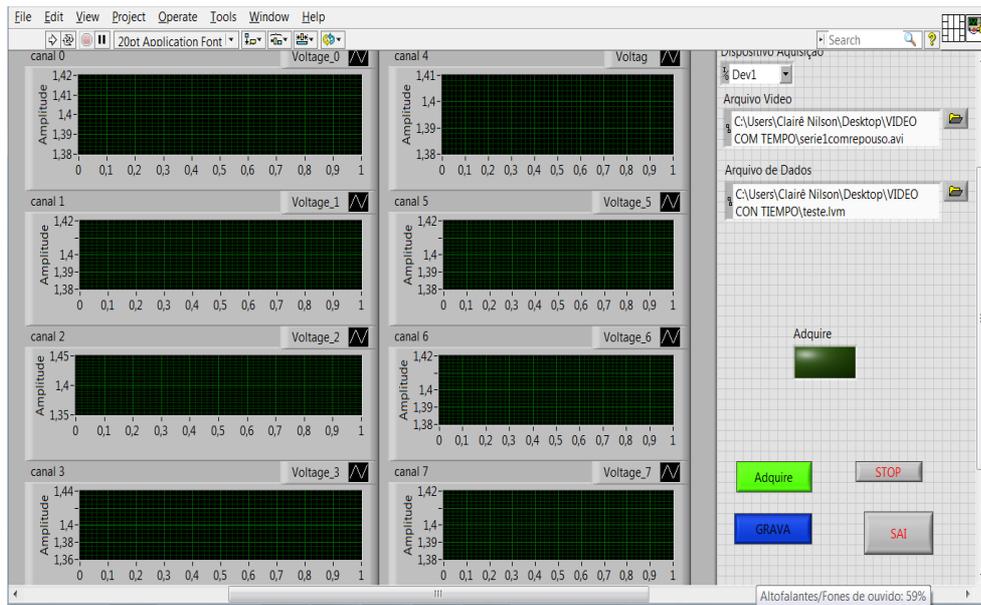


(a)

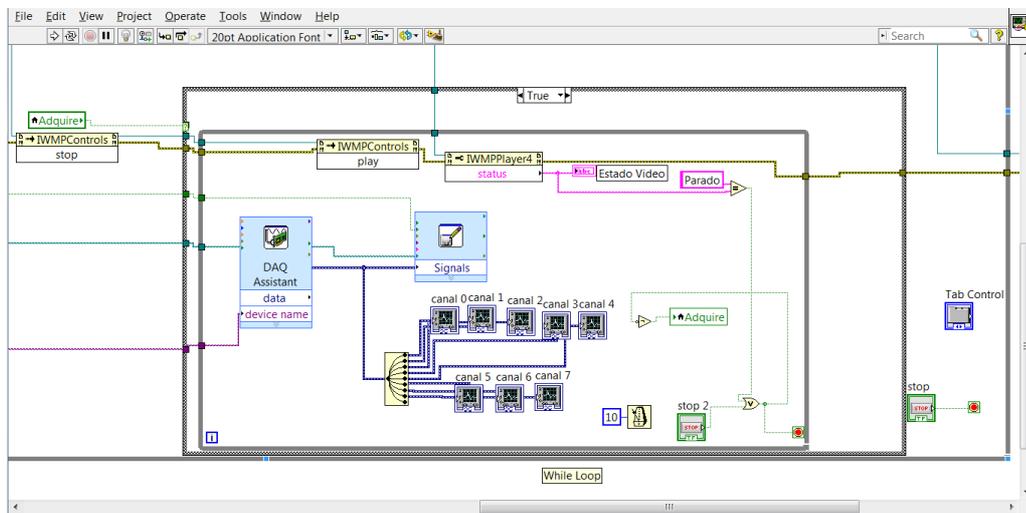


(b)

**Figura 16 Rotina do Modelo Virtual: (a) painel frontal do *LabView* e (b) painel diagrama de blocos do *LabView*: parte da rotina desenvolvida para a visualização das animações.**

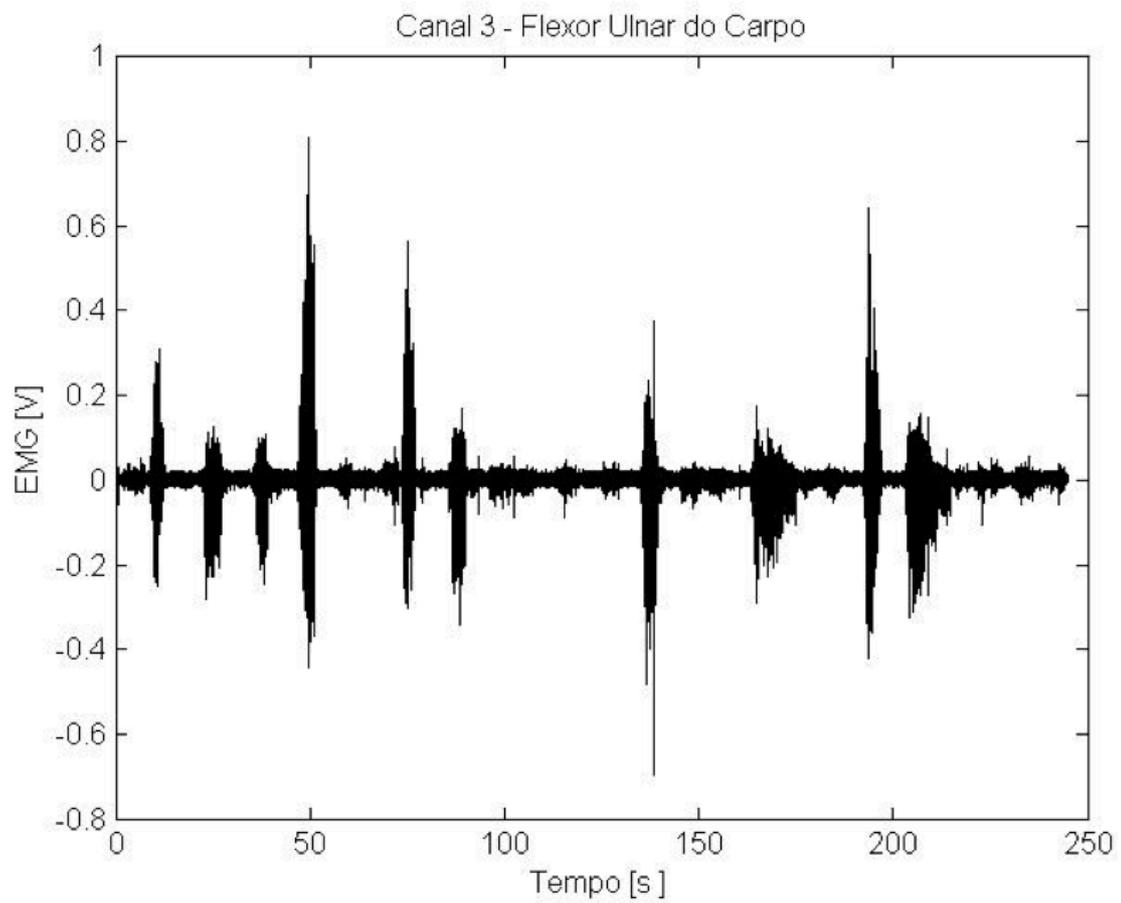
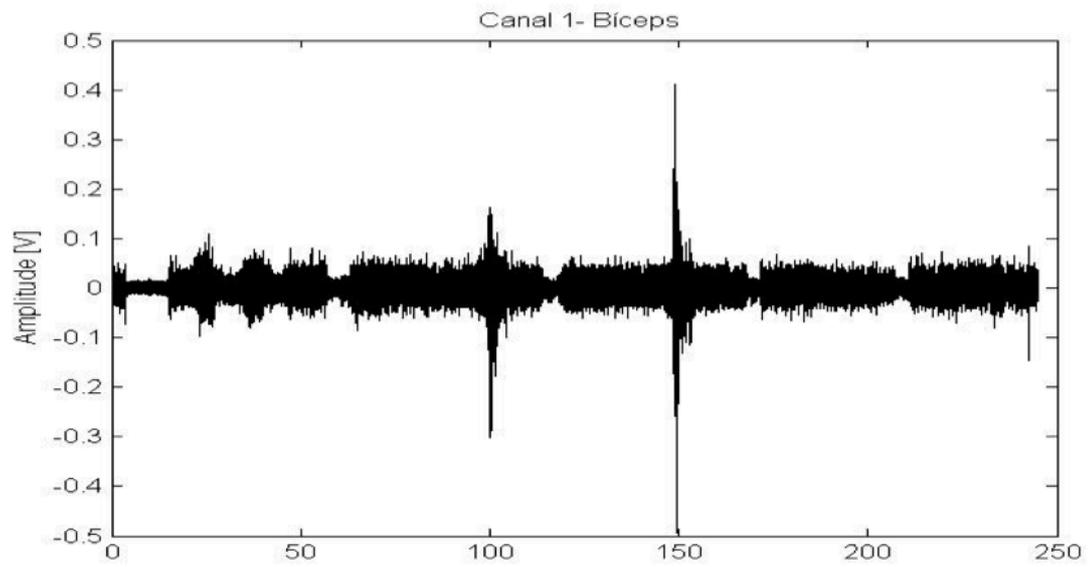


(a)



(b)

Figura 17 Rotina de aquisição de dados: (a) painel frontal do *LabView* e (b) painel diagrama de blocos.



**Figura 18** Sinais de EMG adquiridos com dois canais executando a série G.

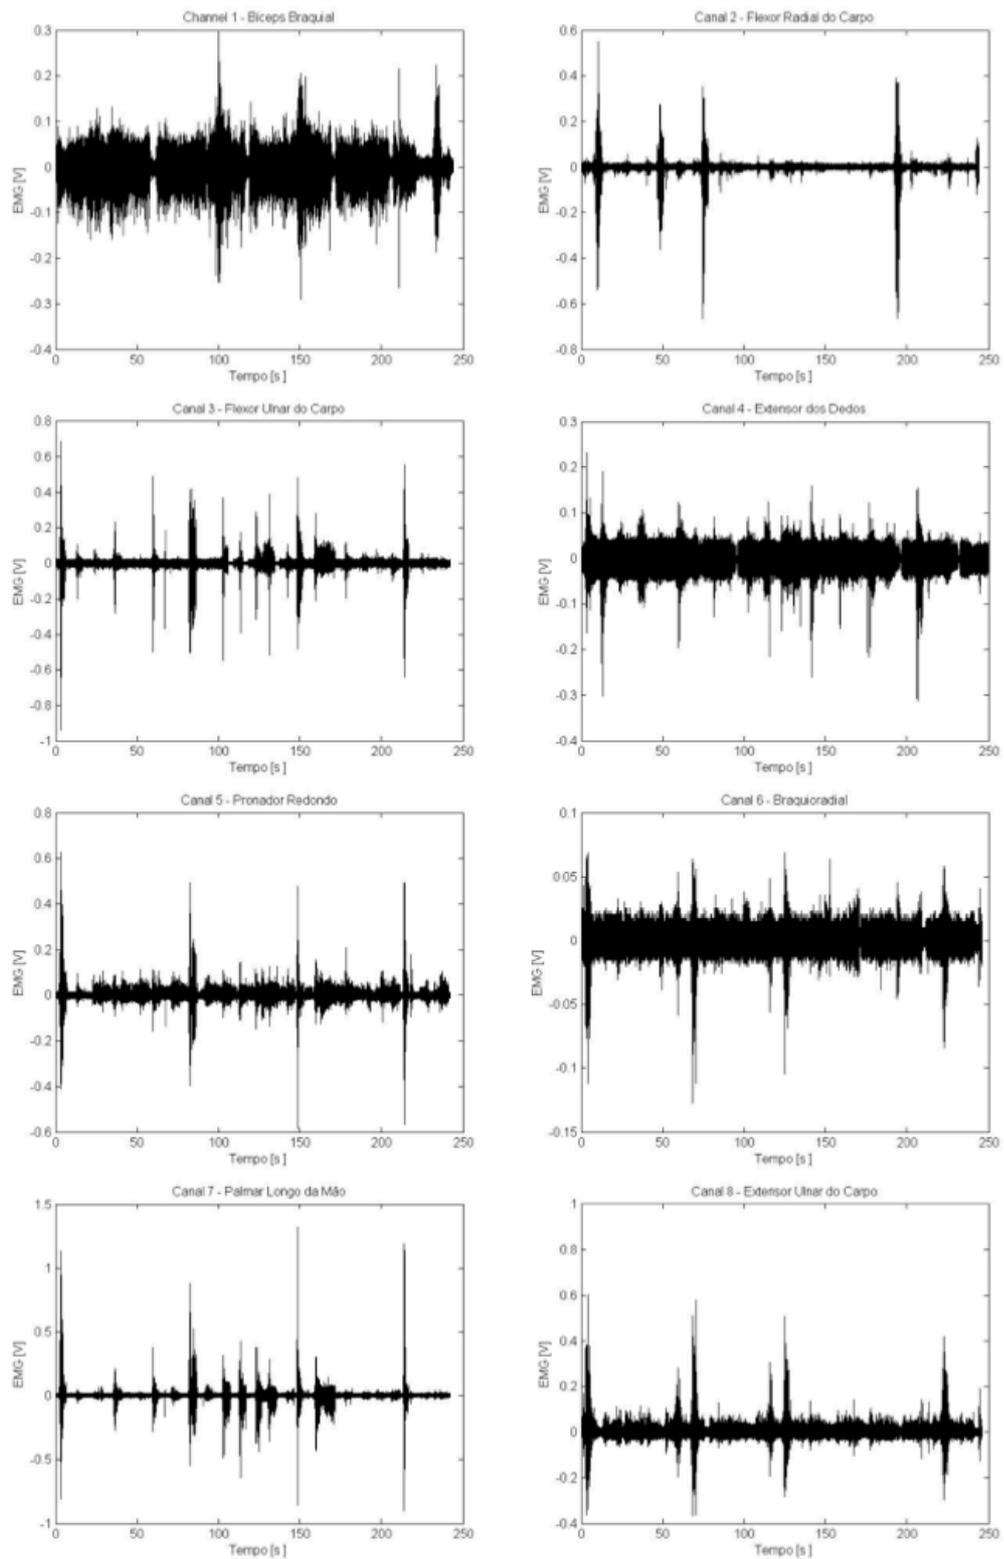


Figura 19 Sinais de EMG adquiridos com oito canais executando a série B.

### 3.3 POSICIONAMENTO DOS ELETRODOS DE SUPERFÍCIE

Neste trabalho, foram usados eletrodos de superfície para evitar o desconforto e a dor causados na inserção do eletrodo de agulha. Segundo BASMAJIAN & DE LUCA (1985), a colocação dos eletrodos, a sua orientação, a área de contato, a forma e a posição podem influenciar na magnitude e no formato do sinal adquirido. Para se obter a máxima potência do sinal e registros consistentes da atividade muscular, o eletrodo foi posicionado na parte ventral do músculo conforme sugestões do *Atlas of Electromyography* (LEIS & TRAPANI, 2000). O tipo de eletrodo de superfície utilizado foi o Eletrodo Descartável Meditrace 100 Pediátrico – KENDALL – Código 001942. Foram realizados procedimentos clássicos de limpeza, como por exemplo, o braço do voluntário é higienizado com a aplicação de álcool e finalizado com uma gaze seca. O eletrodo é pressionado firmemente no centro e ao redor, nas bordas laterais, sendo fixado firmemente com uma faixa adesiva para obter registros consistentes da atividade muscular. Após o posicionamento correto dos eletrodos, o voluntário é instruído a replicar as animações do modelo virtual que aparecem no vídeo na tela de LCD.

### 3.4 PRÉ- PROCESSAMENTO DO SINAL DE EMG

No computador, o sinal de EMG pode ser tratado de diversas formas para obter as informações de maneira a comandar dispositivos externos, como por exemplo, um braço mecânico. A Figura 20 apresenta o diagrama de blocos de parte da etapa de pré-processamento do sinal desenvolvido no *software Matlab*. Essa etapa consiste na remoção do *offset* do sinal, filtragem e segmentação do sinal de interesse. As características utilizadas neste trabalho são: RMS, média, variância, desvio padrão, *skewness* e *kurtosis*. Essas

características são os parâmetros de entrada do classificador. Nos próximos sub-capítulos são apresentados discussões completas de cada um desses blocos.

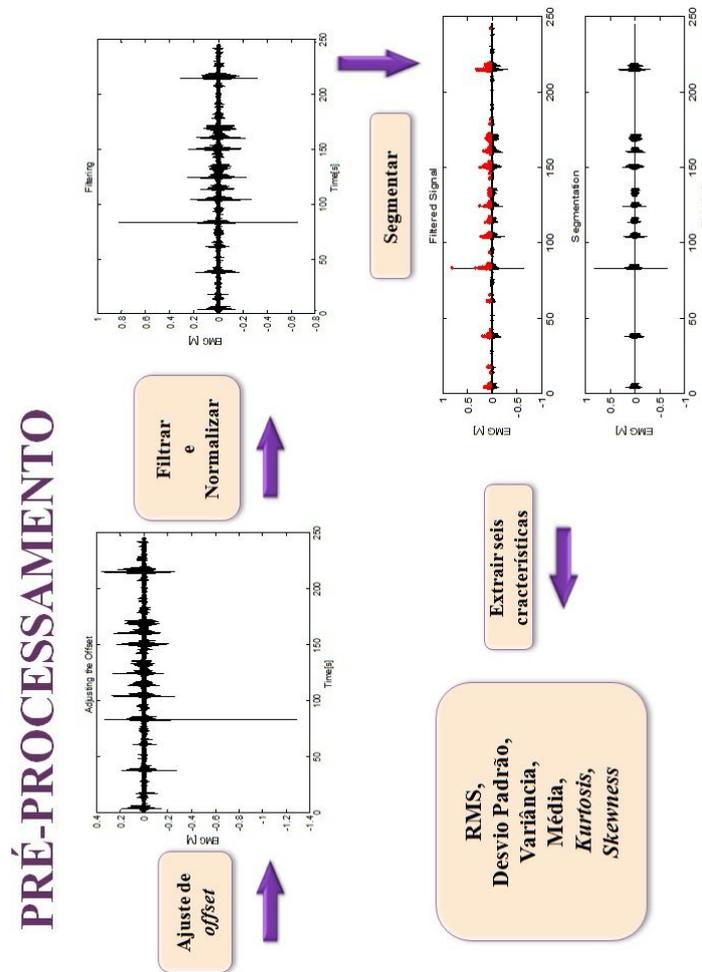
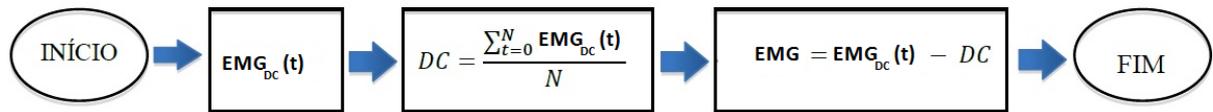


Figura 20 Diagrama de Blocos de parte da etapa de Pré-Processamento.

### 3.4.1 Ajuste de *offset* e Filtragem Digital

O componente DC pode ser adicionado ao Sinal Mioelétrico no momento do condicionamento e da aquisição do mesmo. O procedimento adotado para o ajuste de offset foi calcular o componente DC, através da média aritmética do Sinal Mioelétrico, e subtraí-lo do Sinal Mioelétrico, conforme mostra o fluxograma da Figura 21.

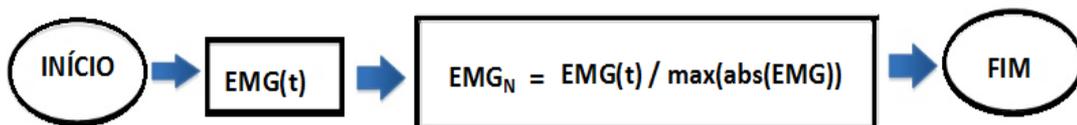


**Figura 21 Fluxograma do ajuste de *offset*.**

O filtro utilizado foi um passa-banda com frequências de corte em 20 Hz e 500 Hz, de quarta ordem e com resposta *Butterworth*. As frequências de corte foram escolhidas baseadas na faixa de frequência do sinal mioelétrico, que se encontra, principalmente, entre 20 a 500 Hz, sendo que a maior parte da energia do sinal se localiza na faixa de 50 a 150 Hz. *Butterworth*, por sua vez, foi escolhido porque é desenvolvido de modo a obter uma resposta em frequência mais plana possível, ou seja, não possui *ripple* ou ondulações na banda passante, e se aproxima de zero na banda rejeitada, além disso, possui uma queda em sua magnitude como uma função linear (BERMUDEZ, 2013; FAVIEIRO, 2012).

### 3.4.2 Normalização do Sinal de EMG

Estudos revelam que dados submetidos a normalização antes do treinamento apresentam melhores resultados finais (HSU, CHANG & LIN, 2004). A Figura 22 apresenta o fluxograma para a etapa da normalização em magnitude dos dados de entrada do classificador.



**Figura 22 Fluxograma do cálculo da normalização.**

As informações são organizadas em uma matriz na qual cada linha é uma amostra e as colunas são as características seguindo o padrão de entrada da SVM.

### 3.4.3 Segmentação

Segundo a metodologia adotada para aquisição dos dados, o sinal EMG adquirido do segmento mão-braço é composto por séries pré-determinadas de movimentos (ver Tabela 5). Porém esse sinal deve ser dividido em segmentos ou regiões que apresentam MUAPS significativos para análises de dados, ou seja, regiões ou áreas de baixa atividade muscular são descartadas por não representarem os movimentos executados pelo voluntário. Portanto, segmentar é detectar quando um movimento começa e quando termina no registro do sinal.

O procedimento utilizado para segmentação constituiu-se em:

- a) dividir o Sinal Mioelétrico em janelas de 250ms buscando sempre atividade EMG. O tempo de segmentação foi determinado com base na duração de cada movimento e no repouso, além de representar um conjunto de MUAPS de forma significativa;
- b) segundo Christodoulou e Pattichis (1995) e Kaur, Arora e Jain (201) sempre que na janela de tempo processada (250ms) ocorrer picos sobre um limiar calculado estes picos são considerados candidatos a constituir MUAPs. Esse limiar (*threshold*) é calculado em função do valor máximo (max) e da média do valor absoluto (MVA) de todo o sinal de EMG. A média do valor absoluto (MVA) é determinada pela Equação (20).

$$MVA = \frac{1}{n} \sum_{i=1}^n |EMG| \quad (20)$$

Se o valor máximo (max) é maior que 30 vezes a MVA, então o *threshold* (Th) é calculado através da Equação (21).

$$Th = 5MVA \quad (21)$$

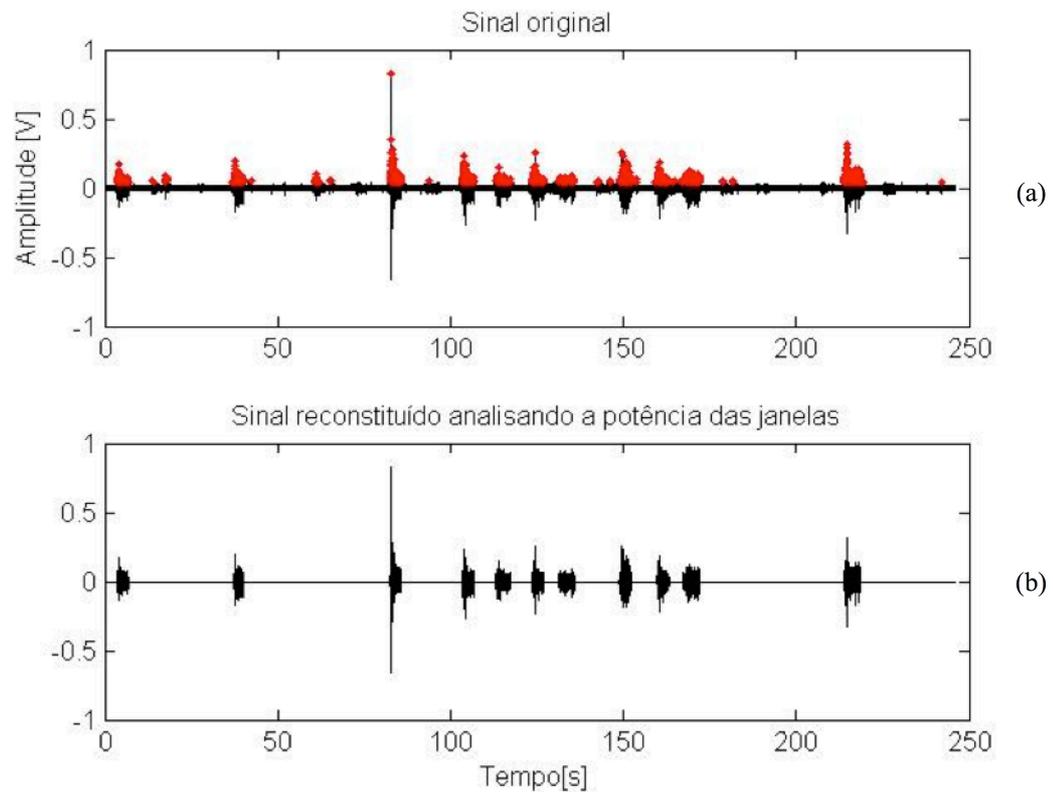
Do contrário o *threshold* (Th) é calculado através da Equação (22):

$$Th = \max/5 \quad (22)$$

- c) a janela é considerada válida, ou não, utilizando-se a potência média do Sinal Mioelétrico. A geração da rotina de validação da janela através da potência média do Sinal Mioelétrico foi desenvolvida por (BERMUDEZ, 2013).

Os dados capturados são armazenados considerando-se um (1) quando a janela é considerada válida, indicando a existência do MUAP e zero (0) quando a janela não é considerada válida, indicando a ausência do MUAP (BERMUDES, 2013).

A Figura 23 apresenta um voluntário executando a Série D. Para apresentar essa fase de pré-processamento, foi selecionado o canal 2 apenas como exemplo. Na Figura 23 (a) os picos assinalados pela cor mais clara indicam que o sinal EMG ultrapassou o limiar determinado. A Figura 23 (b) apresenta a segmentação contendo as janelas ativas validadas pela potência média do Sinal Mioelétrico. O sinal segmentado foi reconstituído sob a base de tempo do sinal original. Os movimentos não selecionados ficaram abaixo do limiar ou não foram validados pela potência da janela.



**Figura 23 Sinal DE EMG: (a) sinal original e (b) segmentação reconstituída sob a base de tempo do sinal original.**

A determinação de qual movimento está sendo executado é feita baseada no tempo que este movimento foi realizado. Na Figura 24 observa-se a segmentação realizada no canal 1, quando um voluntário está realizando a Série D. Baseando-se na sequência desta série, explicada no item 3.1.3 série de movimentos, obtém-se que o primeiro movimento executado é a contração da mão e flexão do antebraço.

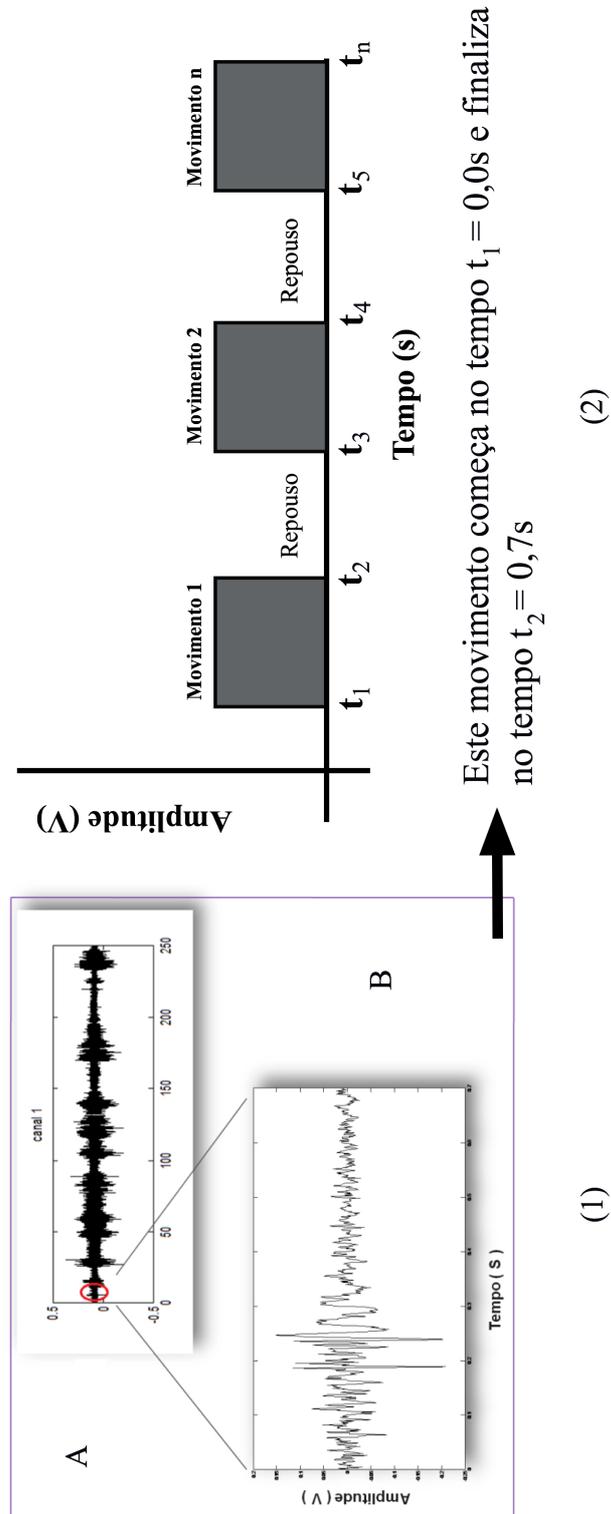


Figura 24 (1.A) Exemplo do Sinal Mioelétrico do canal 1 executando a série D, (1.B) trecho do sinal indicando a contração da mão e flexão do antebraço e (2) série de movimentos (Adaptado de BERMUDES, 2013).

### 3.4.4 Extração de Características do Sinal de EMG

Os movimentos selecionados, que ficaram acima do limiar e foram validados pela potência da janela de 250ms, passam agora pela extração de características.

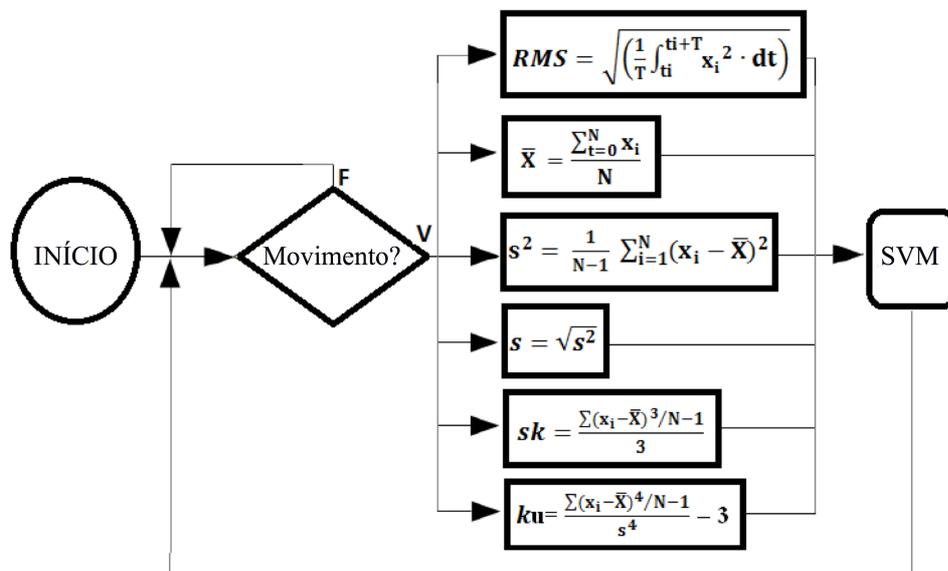
A ferramenta utilizada para obter as características dos vetores que contém o sinal segmentado foi a Transformada Discreta *Wavelet* (DWT). Essa transformada decompõe os sinais de EMG nas frequências que a compõem, permitindo uma análise em vários níveis de decomposição e é ótimo para sinais não estacionários, como os sinais de origem biológica que mudam suas propriedades consideravelmente com o passar do tempo. A análise *Wavelet* consiste em adotar uma função base (*mother wavelet*) e representar o sinal original como uma combinação linear de decomposições sobre a função base (BERMUDEZ, 2013; CHAGAS, 2009; CLEMENTE, 2008; MAZURKIEWICZ, 2007; RICCIOTTI, 2006):

1. Primeiramente escolhe-se *mother Wavelet* para fazer a análise do sinal segmentado. A DWT utilizada foi a *Daubechies* de ordem oito, suas particularidades a tornam apropriada para detectar mudanças em sinais de EMG (BERMUDEZ, 2013; CHAGAS, 2009; CLEMENTE, 2008; MAZURKIEWICZ, 2007; RICCIOTTI, 2006).
2. A decomposição realizou-se em quatro níveis de detalhes (baixas frequências) e quatro aproximações (altas-frequências), ou seja, o sinal original corresponde à soma de aproximações e detalhes. Em cada decomposição se extraiu as características dos vetores que contém o sinal segmentado de cada canal. As características obtidas matematicamente foram: RMS, média aritmética ( $\bar{X}$ ), variância ( $s^2$ ), desvio padrão ( $s$ ), *skewness* (sk) e *kurtosis* (ku) (BERMUDEZ, 2013; CHAGAS, 2009; CLEMENTE, 2008; MAZURKIEWICZ, 2007; RICCIOTTI, 2006). É importante observar que estas características foram avaliadas para permitir que os resultados deste trabalho sejam comparados com o trabalho de BERMUDEZ (2013). Mesmo que as

métricas para avaliação da dispersão de dados sejam similares como, por exemplo, neste trabalho, as métricas variância e desvio padrão. Ambas foram utilizadas para permitir a avaliação futura de qual métrica é mais representativa para esses sinais EMG. Essa mesma afirmação é válida para outras métricas similares utilizadas neste trabalho.

- Os dados foram armazenados de forma a obter uma matriz onde cada linha é uma amostra dos sinais segmentados de cada canal e as colunas são as características desses sinais.

A Figura 25 apresenta o fluxograma para o cálculo das seis características do sinal de EMG que foram obtidas a partir dos vetores que contém o sinal segmentado ( $x_i$ ).



**Figura 25 Fluxograma do cálculo do valor RMS, média aritmética ( $\bar{X}$ ), variância ( $s^2$ ), desvio padrão ( $s$ ), *skewness* ( $sk$ ) e *kurtosis* ( $ku$ ).**

A variância, o desvio padrão, o *skewness* - coeficiente de assimetria- e a *kurtosis* - que caracteriza o pico ou "achatamento" da curva da função de distribuição- são medidas de dispersão dos dados.

### 3.5 PROCESSAMENTO DO SINAL UTILIZANDO A SVM

A etapa de caracterização dos movimentos do segmento mão-braço foi realizada através da Máquina de Vetores de Suporte, descrita no Capítulo 2.4. Esse sistema tem como entrada os valores RMS, média aritmética, variância, desvio padrão, *skewness* e *kurtosis* de cada canal de aquisição dos dados. Apresenta como saída os movimentos caracterizados que estão sendo realizados pelos usuários. A SVM utilizada, neste trabalho, foi implementada utilizando a ferramenta *Matlab*, mais especificadamente através da “(L2) SVM Classification Toolbox”. O método utilizado para resolver o problema de classificação de múltiplas classes, com várias classificações binárias, foi um contra todos (*one versus all*).

Os próximos sub-capítulos apresentam discussões completas do sistema desenvolvido. São indicados os parâmetros utilizados e como foi realizado o processo de treinamento da rede e a sua utilização para reconhecer os movimentos do segmento mão-braço.

#### 3.5.1 Dimensionamento da SVM

O formato dos dados de entrada da máquina de vetores de suporte foi organizado de forma a obter uma matriz onde cada linha é uma amostra dos sinais segmentados de cada canal e as colunas são as características (RMS, média, variância, desvio padrão, *skewness* e *kurtosis*) desses sinais. As classes dos movimentos são organizadas de forma a compor um vetor com o índice do movimento, vetor com as *labels* de cada amostra. Os dados de saída são formados por uma matriz com as saídas esperadas para os dados de entrada definidos, de forma que as linhas apresentam a classe real e as colunas à classe prevista dos movimentos executados.

### 3.5.2 Treinamento da SVM

A capacidade de generalização do modelo, o desempenho e a predição é realizada a partir do conjunto de dados. A solução simples usada é dividir os dados em conjuntos de treinamento e de teste. Geralmente, quanto maior o arquivo de treinamento melhor o classificador, e quanto maior o arquivo de teste mais exata será a estimativa de erro (HAYKIN, 2001; ENGUEL, 2013; CABENA, 1997). Um algoritmo de indução de conhecimento é aplicado à base de treinamento obtendo um modelo inteligente que adquire conhecimento. O modelo obtido é aplicado a base de testes. Como a base de testes, previamente rotulada, se pode medir a taxa de acerto do modelo, comparando-se o resultado obtido com a rotulação contida na base de testes (CABENA, 1997).

### 3.5.3 Validação Cruzada

A validação cruzada (*cross-validation*) é o mecanismo utilizado para avaliar a taxa de acerto. Existem diversas formas de realizar o particionamento das amostras representativas do problema (conjuntos de treinamento e de teste), sendo as três mais utilizadas: o método *holdout* (retenção), o *k-fold* (k-vezes) e o *leave-one-out* (deixar um fora). O método *holdout* utiliza certa quantidade dos dados para teste e emprega o resto para o treinamento. No *k-fold* o conjunto de dados é dividido em  $k$  subconjuntos de tamanhos iguais. Cada subconjunto é usado para teste e os demais para treinamento, repetindo, esse processo,  $k$  vezes. No *leave-one-out* o número de vezes é escolhido como o número de exemplos de treinamento, ou seja, é necessário construir  $n$  classificadores, sendo  $n$  o número de exemplos de treinamento (CAWLEY, 2006; ENGUEL, 2013).

As duas técnicas escolhidas foram *k-fold* (k-vezes) e *leave-one-out* (deixar um fora). Utilizou-se  $k=10$  no método *k-fold* pois, experimentalmente, este valor é a melhor escolha para se obter uma estimativa precisa.

Para a representação dos gráficos a técnica escolhida foi *leave-one-out* (deixar um fora). Com essa técnica pode-se obter uma estimativa mais precisa da validação, aproveitando ao máximo os dados, apesar da desvantagem de possuir custo computacional mais elevado (CAWLEY, 2006; ENGUEL, 2013).

#### 3.5.4 Matriz de Confusão

Segundo Cawley (2006) e Chagas (2009) a taxa de erro é considerada uma medida natural de desempenho de classificação, apesar disso, ela não distingue entre erros feitos sobre exemplos de uma classe e as demais. A matriz de confusão é uma ferramenta que contabiliza os acertos e os erros de cada classe. A matriz é perpetrada de forma que as linhas apresentam a classe real e as colunas à classe prevista, uma tabulação cruzada entre a classe prevista pelo modelo e a classe real dos exemplos, tendo como resultado na diagonal principal os acertos de cada classe. Para facilitar o entendimento, é apresentado um exemplo. Considere um problema de classificação com apenas duas classes (rotuladas como positivas e negativas) a matriz de confusão é utilizada para análise de previsões verdadeiras (acertos) e falsas (erros), conforme mostra a Tabela 6.

**Tabela 6 Matriz de Confusão.**

		Classe prevista	
		Positiva	Negativa
Classe real	Positiva	Soma de classificações Verdadeiras Positivas (VP)	Soma de classificações Falsas Positivas (FN)
	Negativa	Soma de classificações Falsas Positivas (FP)	Soma de classificações Verdadeiras Negativas (VN)

- a) Verdadeiro Positivo (VP): o exemplo pertence à classe positiva e o classificador prediz que o exemplo pertence à classe positiva;
- b) Verdadeiro Negativo (VN): o exemplo pertence à classe negativa e o classificador prediz que o exemplo pertence à classe negativa;
- c) Falso Positivo (FP): o exemplo pertence à classe negativa e o classificador prediz que o exemplo pertence à classe positiva;
- d) Falso Negativo (FN): o exemplo pertence à classe positiva e o classificador prediz que o exemplo pertence à classe negativa.

Segundo Cawley (2006), baseado na matriz de confusão podem ser definidas algumas métricas de avaliação. As mais usadas são a taxa de acerto (Txc) e erro (Err), determinados pelas Equações (23) e (24) respectivamente:

$$T_{xc} = \frac{VP+VN}{n} \quad (23)$$

$$Err = \frac{FP+FN}{n} \quad (24)$$

onde, P é número de exemplos positivos, N é número de exemplos negativos e n é o número total de exemplos ( $n = VP + VN + FP + FN$ ).

A taxa de VP (TVP), *sensitivity* ou *recall* ( $r$ ) que é a fração dos exemplos positivos previstos corretamente e a taxa de VN (TVN), *specificity* ou *fall-out* que é a fração dos exemplos negativos previstos corretamente são determinadas pelas Equações (25) e (26) respectivamente.

$$\text{TVP} = r = \frac{VP}{VP+FN} \quad (25)$$

$$\text{TVN} = \frac{VN}{VN+FP} \quad (26)$$

## 4 RESULTADOS E DISCUSSÕES

Este capítulo irá abordar os resultados obtidos durante o desenvolvimento do sistema e, na sequência, as respectivas discussões.

Considerações importantes:

- a) os resultados obtidos foram tabelados e analisados em termos da taxa de acerto e da matriz de confusão (também chamada de tabela de contingência);
- b) a SVM utilizada foi linear devido a realização de testes preliminares que demonstraram bons resultados;
- c) para avaliar a relação entre o número de canais com a taxa de acertos foram adquiridos os sinais com dois canais e depois em oito canais, utilizando seis características (RMS, média, variância, desvio padrão, *skewness*, *kurtosis*) para processar o sinal na SVM;
- d) para avaliar a relação entre o número de características com a taxa de acertos foram adquiridos os sinais em oito canais e variado o número de características;
- e) a comparação dos métodos de validação cruzada, *leave-one-out* e *k-fold* foram realizadas com dois e oito canais e devido ao número de características.

### 4.1 SINAIS ADQUIRIDOS COM DOIS CANAIS

Para avaliar a relação entre o número de canais com a taxa de acertos, primeiramente os sinais foram adquiridos com dois canais posicionados nos músculos Bíceps Braquial e Flexor Ulnar do Carpo de três voluntários, utilizando-se seis características (RMS, média, variância, desvio padrão, *skewness*, *kurtosis*). Dois métodos de validação foram usados para

avaliar a taxa de acerto média, *leave-one-out* e *k-fold*, variando o parâmetro de regularização (C) da SVM em 100, 1.000 e 10.000.

#### 4.1.1 Voluntário I

Para o Voluntário I foram analisadas três séries (F, C e E), utilizando seis características (RMS, média, variância, desvio padrão, *skewness*, *kurtosis*), obtidas a partir dos vetores que contém o sinal segmentado de dois canais, posicionados nos músculo Bíceps Braquial e ao Flexor Ulnar do Carpo, para processar o sinal na SVM. O parâmetro de regularização (C) da SVM, foi ajustado baseado nos resultados dos dados de teste. Nas Tabelas 7, 8 e 9 encontra-se os resultados, da taxa de acerto média, obtidos da variação do parâmetro de regularização (C) da SVM em 100, 1.000 e 10.000, para os métodos de validação *leave-one-out* e *k-fold*, respectivamente. É importante ressaltar que a taxa de acerto média representa o percentual de movimentos relacionados de forma correta.

**Tabela 7 Taxa de acerto média do Voluntário I executando a série F.**

<b>Voluntário I (Série F)</b>	<b>C=100</b>	<b>C=1.000</b>	<b>C=10.,000</b>
<b>Leave-one-out</b>	<b>41,2%</b>	<b>64,7%</b>	<b>88,2%</b>
<b>K-fold (k=10)</b>	<b>45,7%</b>	<b>74,9%</b>	<b>91,4%</b>

**Tabela 8 Taxa de acerto média do Voluntário I executando a série C.**

<b>Voluntário I (Série C)</b>	<b>C=100</b>	<b>C=1.000</b>	<b>C=10.,000</b>
<b>Leave-one-out</b>	<b>35,3%</b>	<b>52,9%</b>	<b>70,6%</b>
<b>K-fold (k=10)</b>	<b>35,4%</b>	<b>61,5%</b>	<b>80,4%</b>

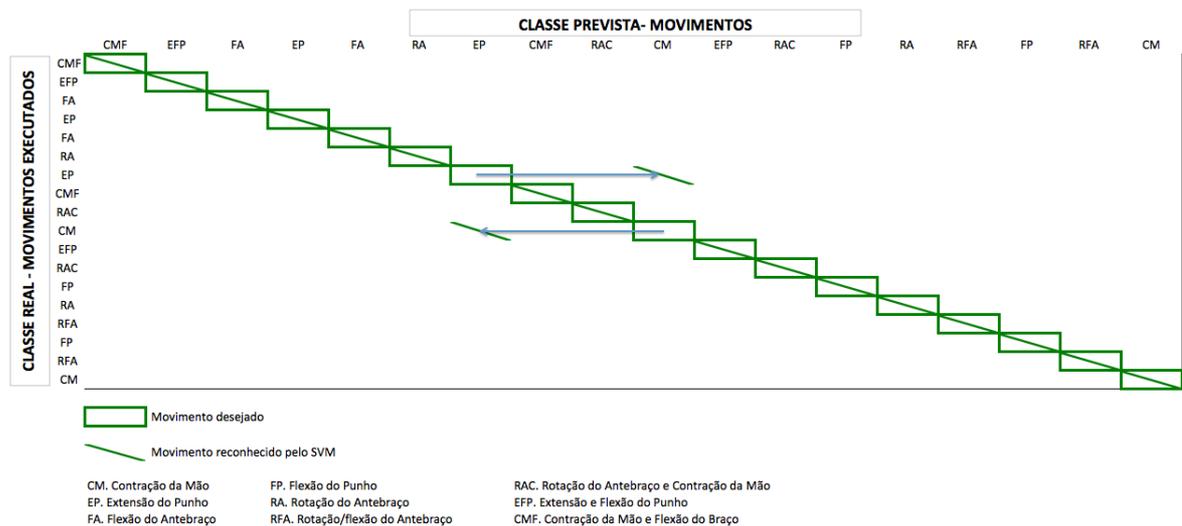
**Tabela 9 Taxa de acerto média do Voluntário I executando a série E.**

<b>Voluntário I (Série E)</b>	<b>C=100</b>	<b>C=1.000</b>	<b>C=10.,000</b>
<b>Leave-one-out</b>	<b>52,9%</b>	<b>64,7%</b>	<b>94,1%</b>
<b>K-fold (k=10)</b>	<b>52,3%</b>	<b>75,1%</b>	<b>94,2%</b>

Concluiu-se que o melhor valor para o parâmetro de regularização (C) da SVM, que se ajusta pelo resultado da avaliação sob os dados de teste, ficou em 10.000, pois obteve uma taxa de acerto média maior. O método *k-fold* apresentou, em todos os testes, uma taxa de acerto média mais elevada que *leave-one-out*, porém a vantagem da validação cruzada por *leave-one-out* é que não envolve sub-amostragem aleatória, sendo o melhor teste estatístico para avaliação com poucos dados, apesar de ser mais custoso computacionalmente.

As Figuras 26, 27 e 28 representam a saída real e a saída desejada da SVM, fixando o parâmetro C em 10.000, e validação cruzada *leave-one-out* para as séries F, C e E do Voluntário I.

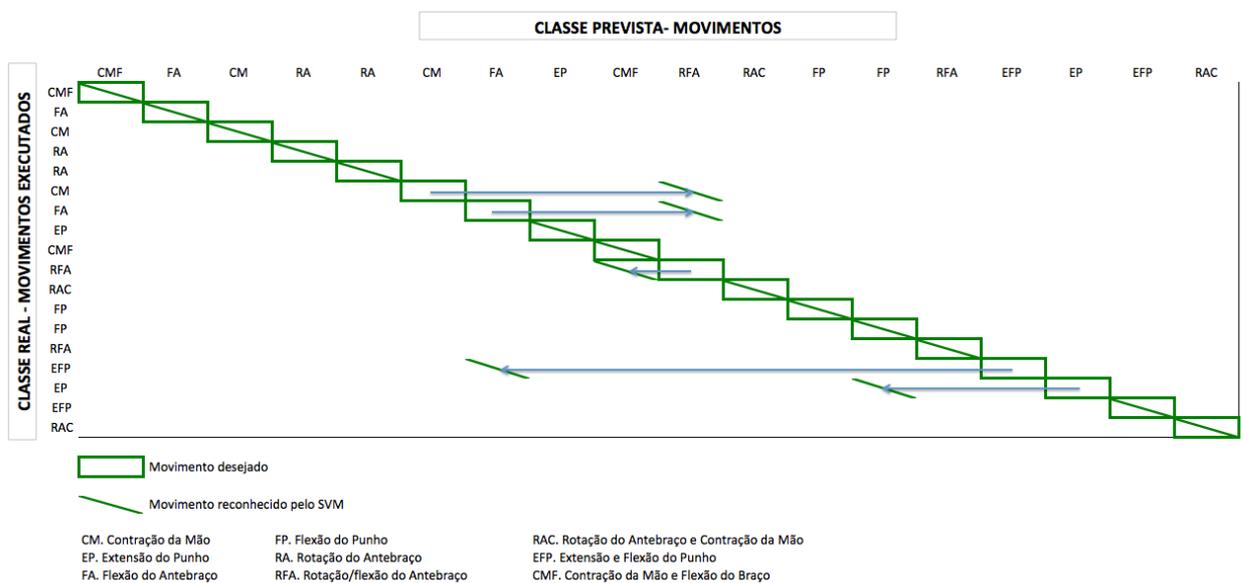
A Figura 26 representando a série F apresentou uma taxa de acerto média de 88,2%, pode-se perceber que ocorreu reconhecimento invertido para o movimento EP, que representa a Extensão do Punho, com o movimento CM (Contração da Mão).



**Figura 26 Saída da SVM para o Voluntário I, executando a série F.**

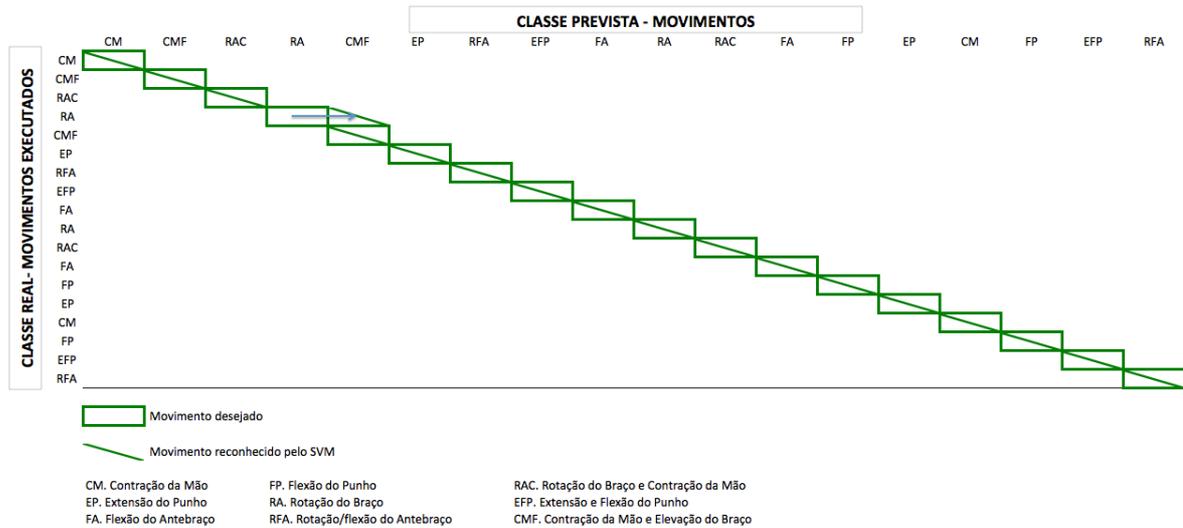
A Figura 27, representando a série C, apresentou uma taxa de acerto média de 70,6%. Para o movimento CM (Contração da Mão), o erro foi devido ao fato de que a rede acreditou

se tratar do movimento RFA (Rotação e Flexão do Antebraço). O movimento FA (Flexão do Antebraço) também foi confundido com RFA, o que representa parcialmente o movimento executado. O próprio RFA também foi confundido com o movimento CMF (Contração da Mão e Flexão do Antebraço). Outros dois movimentos que ocorreram reconhecimento incorreto foram o EFP (Extensão e Flexão do Punho) com FA (Flexão do Antebraço) e EP (Extensão do Punho) com FP (Flexão do Punho).



**Figura 27 Saída da SVM para o Voluntário I, executando a série C.**

A Figura 28, representando a série E, apresentou uma taxa de acerto média de 94,1%, adotando  $C=10.000$  e validação cruzada *leave-one-out*. O movimento RA (Rotação do Antebraço) foi confundido com o movimento CMF (Contração da Mão e Flexão do Antebraço).



**Figura 28 Saída da SVM para o Voluntário I, executando a série E.**

A Tabela 10 apresenta, para cada movimento por série, a taxa de acerto média do sistema e a média geral de cada movimento do voluntário I.

**Tabela 10 Taxa de acerto média do sistema.**

Voluntário I	CM	EP	FA	FP	RA	CMF	EFP	RFA	RAC
Série F	75%	75%	100%	100%	100%	100%	100%	100%	100%
Série C	75%	75%	75%	100%	80%	100%	50%	50%	100%
Série E	100%	100%	100%	100%	75%	100%	100%	100%	100%
Média Geral	83,3%	83,3%	91,7%	100,0%	85%	100,0%	83,3%	83,3%	100,0%

Observa-se na Tabela 10, na série F, que a Contração da Mão e a Extensão do Punho foram os movimentos que atingiram a menor taxa de acerto: 75%. Na série C, os movimentos que atingiram a menor taxa de acerto foram os movimentos compostos Extensão e Flexão do Punho e Rotação e Flexão do Antebraço com 50%. Na série E, o movimento que atingiu a menor taxa de acerto foi Rotação do Antebraço com 75%. Na média geral os movimentos com a menor taxa de acerto foram a Contração da Mão, Extensão do Punho, Extensão e Flexão do Punho e Rotação e Flexão do Antebraço com 83,3 %.

#### 4.1.2 Voluntário II

Para o Voluntário II foram analisadas duas séries, C e D. Utilizou-se seis características (RMS, média, variância, desvio padrão, *skewness*, *kurtosis*) e dois canais posicionados nos músculos Bíceps Braquial e ao Flexor Ulnar do Carpo. O parâmetro de regularização (C) da SVM foi ajustado baseado nos resultados dos dados de teste. As Tabelas 11 e 12 apresentam os resultados da taxa de acerto média, obtida da variação do parâmetro de regularização (C) da SVM (em 100, depois 1.000 e 10.000). Dois métodos de validação cruzada, *leave-one-out* e *k-fold*, foram usados para o Voluntário II executando as séries C e D, respectivamente.

**Tabela 11 Taxa de acerto média do Voluntário II executando a série C.**

<b>Voluntário II (Série C)</b>	<b>C=100</b>	<b>C=1.000</b>	<b>C=10.000</b>
<b>Leave-one-out</b>	<b>41,2%</b>	<b>76,5%</b>	<b>76,5%</b>
<b>K-fold (k=10)</b>	<b>53,3%</b>	<b>87,0%</b>	<b>87,6%</b>

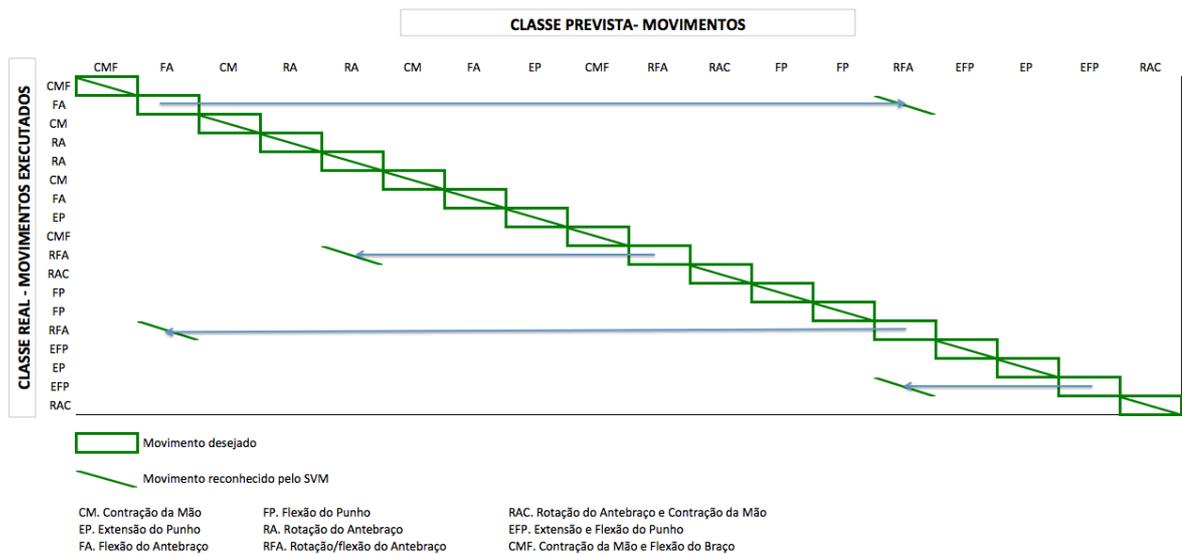
**Tabela 12 Taxa de acerto média do Voluntário II executando a série D.**

<b>Voluntário II (Série D)</b>	<b>C=100</b>	<b>C=1.000</b>	<b>C=10.000</b>
<b>Leave-one-out</b>	<b>23,5%</b>	<b>47,1%</b>	<b>82,4%</b>
<b>K-fold (k=10)</b>	<b>27,3%</b>	<b>66,0%</b>	<b>92,2%</b>

Baseado nos resultados das Tabelas 11 e 12 o parâmetro C e o método de validação cruzada continuaram os mesmos dos ensaios anteriores do Voluntário I, C em 10.000, e validação cruzada *leave-one-out*.

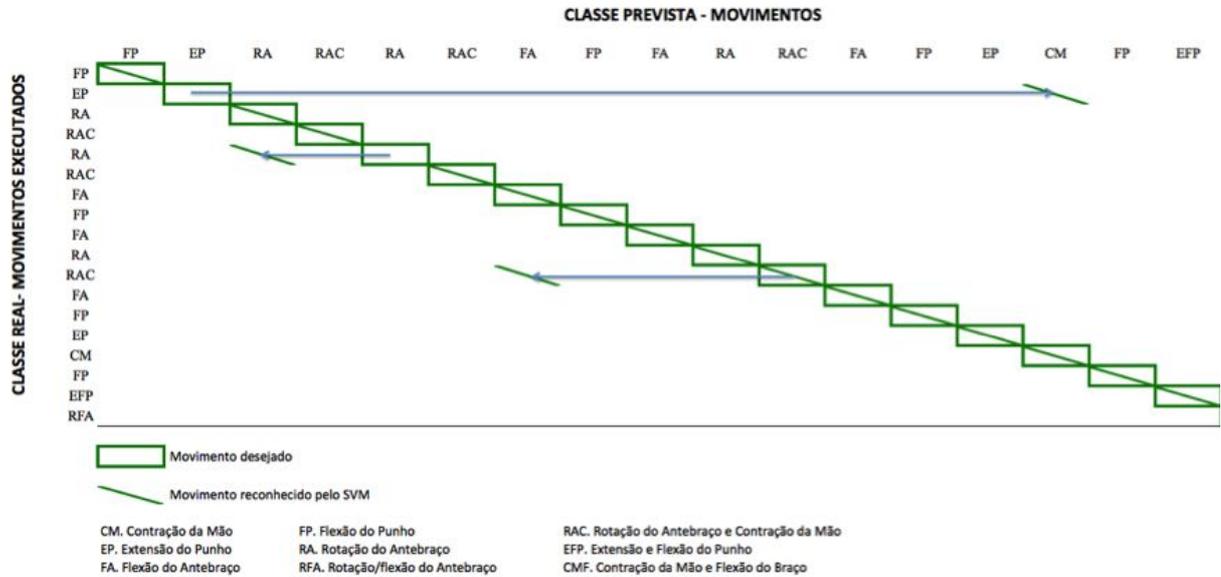
A seguir estão as Figuras 29 e 30, representando a saída real e a saída desejada da SVM. Os dados de teste compreendem as séries C e D, respectivamente.

A Figura 29, com o voluntário II executando a série C, apresentou uma taxa de acerto média de 76,5%. Pode-se perceber que o movimento que mais errou foi o RFA que representa a Rotação e Flexão do Antebraço, o erro foi devido ao fato de que a rede acreditou se tratar do movimento FA (Flexão do Antebraço) e RA (Rotação do Antebraço). Outro movimento em que ocorreu o reconhecimento incorreto foi o EFP (Extensão e Flexão do Punho) com RFA (Rotação e Flexão do Antebraço).



**Figura 29 Saída da SVM para o Voluntário II, executando a série C.**

A Figura 30, com o Voluntário II executando a série D, apresentou uma taxa de acerto média de 82,4%, pode-se perceber que para o movimento EP que representa Extensão do Punho, o erro foi devido ao fato de que a rede acreditou se tratar do movimento CM, Contração da Mão. Outro movimento em que ocorreu o reconhecimento incorreto foi o RAC (Rotação do Antebraço e Contração da Mão) com FA (Flexão do Antebraço).



**Figura 30 Saída da SVM para o Voluntário II, executando a série D.**

A Tabela 13 apresenta, para cada movimento por série, a taxa de acerto média do sistema com os métodos *leave-one-out* e *k-fold*, e a média geral de cada movimento. O movimento CMF não existe na série D, e o movimento RFA ficou abaixo do limiar na segmentação para a série D.

**Tabela 13 Taxa de acerto média do sistema.**

Voluntário II	CM	EP	FA	FP	RA	CMF	EFP	RFA	RAC
Série C	100%	100%	60%	100%	100%	100%	100%	67%	100%
Série D	100%	66,6%	100%	100%	80%	-	100%	-	50%
Média Geral	100%	83,3%	80%	100%	90%	-	100%	-	75,0%

#### 4.1.3 Voluntário III

Para o Voluntário III analisou-se duas séries, G e E, com dois canais ligados aos músculos Bíceps Braquial e ao Flexor Ulnar do Carpo. Utilizou-se seis características (RMS, média, variância, desvio padrão, *skewness*, *kurtosis*).

Os resultados, da taxa de acerto média, obtidos da variação do parâmetro de regularização (C) da SVM, para os métodos *leave-one-out* e *k-fold*, encontram-se nas Tabelas 14 e 15.

**Tabela 14 Taxa de acerto média do Voluntário III executando a série F.**

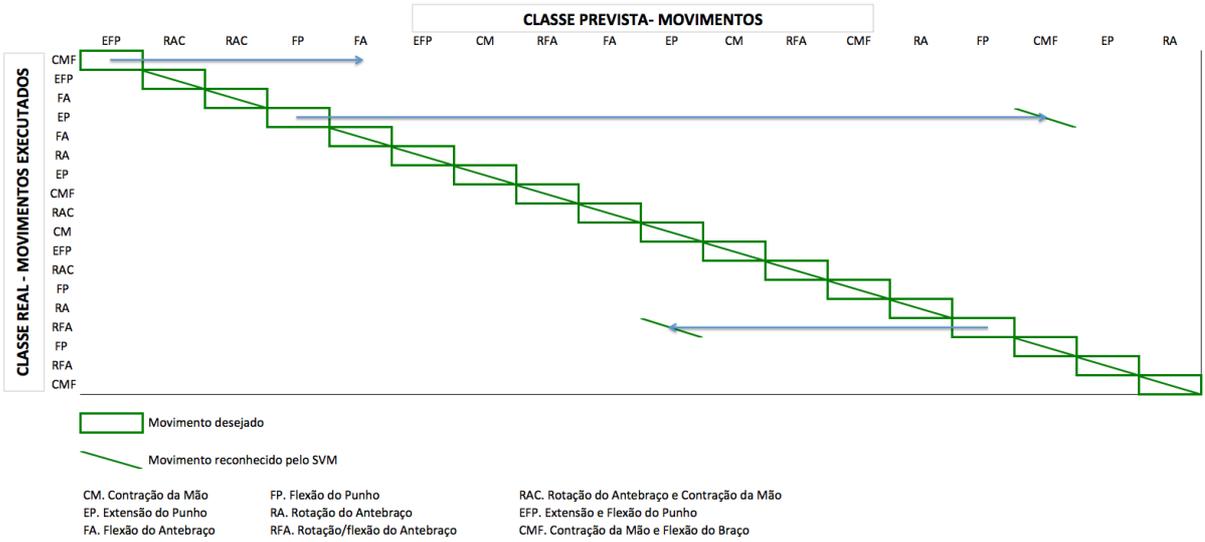
<b>Voluntário III (Série F)</b>	<b>C=100</b>	<b>C=1.000</b>	<b>C=10.000</b>
<b>Leave-one-out</b>	<b>41,2%</b>	<b>76,5%</b>	<b>82,4%</b>
<b>K-fold (k=10)</b>	<b>50,3%</b>	<b>76,4%</b>	<b>96,4%</b>

**Tabela 15 Taxa de acerto média do Voluntário III executando a série E.**

<b>Voluntário III (Série E)</b>	<b>C=100</b>	<b>C=1.000</b>	<b>C=10.000</b>
<b>Leave-one-out</b>	<b>58,8%</b>	<b>76,5%</b>	<b>88,2%</b>
<b>K-fold (k=10)</b>	<b>65,4%</b>	<b>83,1%</b>	<b>92,4%</b>

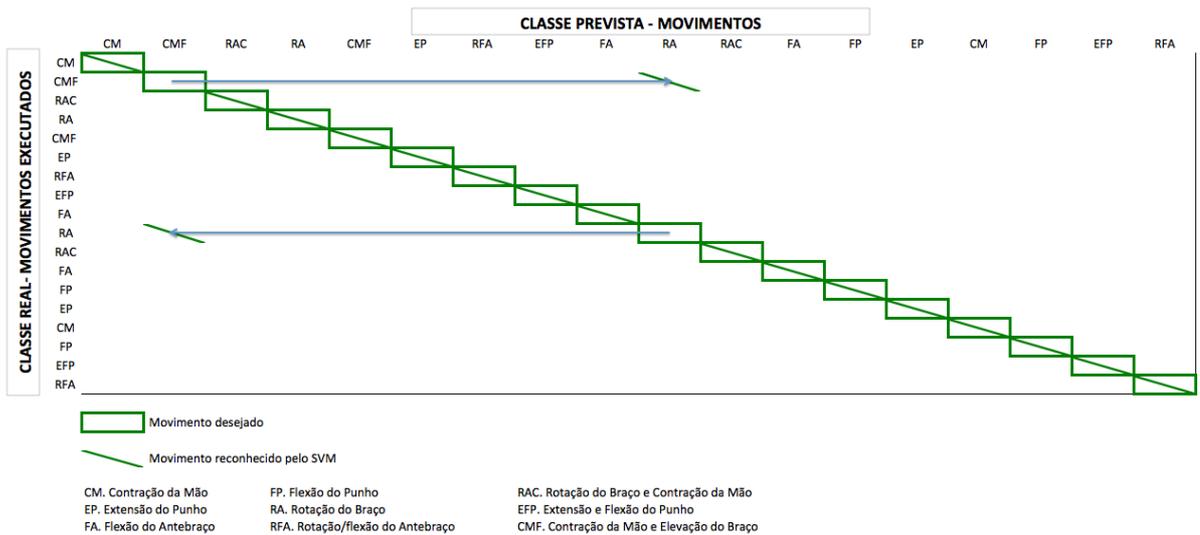
Baseado nos resultados das Tabelas 14 e 15 o parâmetro C continuou o mesmo dos ensaios anteriores dos Voluntários I e II, C em 10.000. A seguir as Figuras 31 e 32 representam a saída real e a saída desejada da SVM, baseadas no método *leave-one-out*.

A Figura 31 com o Voluntário III executando a série G, apresentou uma taxa de acerto média de 82,4% pode-se perceber que o movimento que mais errou foi o FP (Flexão do Punho), sendo que a rede acreditou se tratar do movimento CMF (Contração da Mão e Flexão do Antebraço) e depois confundiu com EP (Extensão do Punho. O movimento EFP (Extensão e Flexão do Punho) confundiu com FA (Flexão do Antebraço).



**Figura 31 Saída da SVM para o Voluntário III, executando a série G.**

A Figura 32, com o Voluntário III executando a série E, apresentou uma taxa de acerto média de 88,2%. Pode-se perceber que o movimento CMF (Contração da Mão e Flexão do Antebraço) a rede acreditou se tratar do movimento RA (Rotação do Antebraço) e vice-versa.



**Figura 32 Saída da SVM para o Voluntário III, executando a série E.**

A Tabela 16 apresenta a taxa de acerto média do sistema, para cada movimento por série, e a média geral de cada movimento do voluntário III.

**Tabela 16 Taxa de acerto média do sistema.**

Voluntário III	CM	EP	FA	FP	RA	CMF	EFP	RFA	RAC
Série G	100%	100%	100%	75%	100%	100%	50%	100%	100%
Série E	100%	100%	100%	100%	83%	50%	100%	100%	100%
Média Geral	100%	100%	100%	87,5%	91,7%	75%	75%	100%	100%

Observa-se na Tabela 16, na série G, que o movimento EFP (Extensão e Flexão do Punho) foi o que atingiu a menor taxa de acerto: 50%. Na série E, o movimento que atingiu a menor taxa de acerto foi o movimento composto CMF (Contração da Mão e Flexão do Antebraço), com 50,0%. A média geral de cada movimento com a menor taxa de acerto foi obtida nos movimentos CMF (Contração da Mão e Flexão do Antebraço) e EFP (Extensão e Flexão do Punho), com 75%.

No final do processo, com a utilização de dois canais, seis características, parâmetro de regularização  $C=10.000$  e validação cruzada *leave-one-out*, os nove movimentos distintos atingiram uma taxa de acerto média de 83,2%.

A má qualidade do sinal, a utilização de apenas dois músculos para obtenção do sinal mioelétrico, o uso de eletrodos superficiais - os quais podem ter captado sinais de músculos próximos - e a possibilidade do voluntário ter executado alguns movimentos de forma incorreta, podem ter contribuído para o aumento da probabilidade de erro no sistema e também na utilização do parâmetro de regularização (C) com um valor muito elevado.

## 4.2 SINAIS ADQUIRIDOS COM OITO CANAIS

Para a análise em oito canais os sinais foram adquiridos, nos mesmos três Voluntários, posicionados nos músculos: Bíceps Braquial (C1), Flexor Radial do Carpo (C2), Flexor Ulnar do Carpo (C3), Extensor dos Dedos (C4), Pronador Redondo (C5), Braquioradial (C6),

Palmar Longo (C7) e Extensor Ulnar do Carpo (C8). Utilizou-se as mesmas seis características (RMS, média, variância, desvio padrão, *skewness*, *kurtosis*). Os mesmos dois métodos de validação foram usados para avaliar a taxa de acerto média, *leave-one-out* e *k-fold*. O parâmetro de regularização (C) da SVM continuou sendo variado em 100, 1.000 e 10.000 para processar o sinal na SVM.

#### 4.2.1 Voluntário I

Para o Voluntário I, foram utilizados somente 6 canais, uma vez que os Canais 2 (Flexor Radial do Carpo) e 4 (Extensor dos Dedos) encontravam-se sem sinal durante parte dos ensaios. Utilizou-se seis características (RMS, média, variância, desvio padrão, *skewness*, *kurtosis*) obtidas a partir dos vetores que contém o sinal segmentado de cada canal. De forma aleatória foram selecionadas as séries D duas vezes.

O parâmetro de regularização (C) da SVM foi ajustado baseado nos resultados dos dados de teste. Na Tabela 17 encontra-se a taxa de acerto média do Voluntário I executando a série D. Dois métodos de validação foram usados para avaliar a taxa de acerto média, *leave-one-out* e *k-fold*, variando o parâmetro de regularização (C) da SVM em 100, 1.000 e 10.000.

**Tabela 17 Taxa de acerto média do Voluntário I executando a série D.**

<b>Voluntário I (Série D)</b>	<b>C=100</b>	<b>C=1.000</b>	<b>C=10.000</b>
<b>Leave-one-out</b>	<b>76,5%</b>	<b>82,4%</b>	<b>88,2%</b>
<b>K-fold (k=10)</b>	<b>76,5%</b>	<b>85,7%</b>	<b>92,2%</b>

Concluiu-se que o valor do parâmetro de regularização (C) da SVM, que se ajusta pelo resultado da avaliação sob os dados de teste, pode ser ajustado em 1.000, diminuindo o tempo

de processamento, pois quanto maior o C, maior o tempo de processamento da SVM. O método *k-fold* apresentou, em todos os testes, uma taxa de acerto média mais elevada que *leave-one-out*.

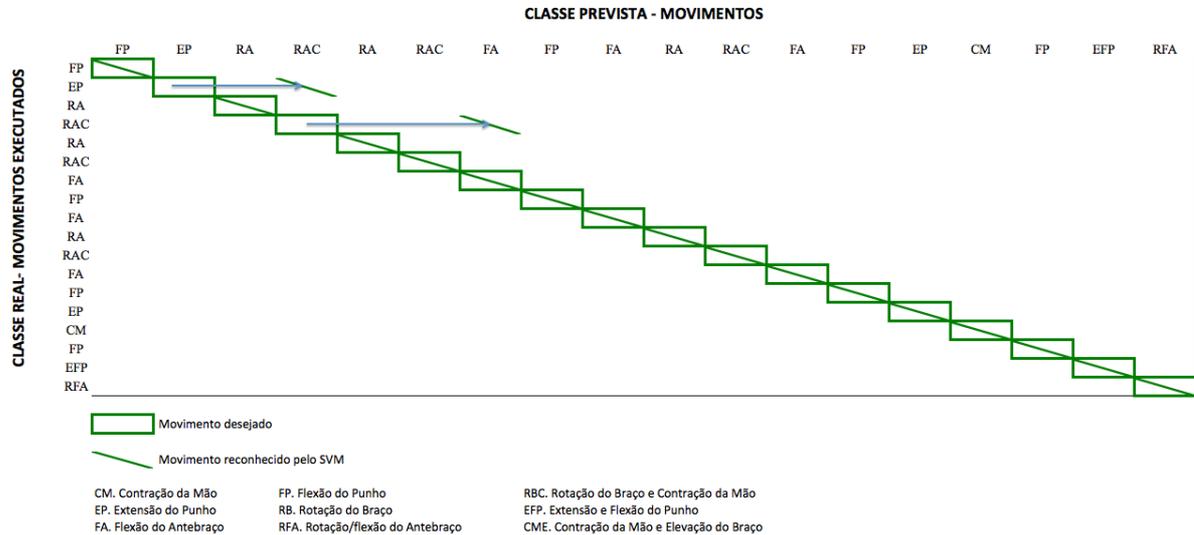
A Figura 33 representa a saída real e a saída desejada da SVM, fixando o parâmetro C em 1.000, e validação cruzada *leave-one-out* para a série D do voluntário I. A taxa de acerto média foi 82,4%. Para o movimento EP (Extensão do Punho), o erro foi devido ao fato de que a rede acreditou se tratar do movimento RAC (Rotação do Antebraço e Contração da Mão). O movimento RA (Rotação do Antebraço) também foi confundido com FA (Flexão do Antebraço). O próprio RA também foi confundido com o movimento EP (Extensão do Punho).



**Figura 33 Saída da SVM para o Voluntário I, executando a série D.**

A Figura 34 representa a saída real e a saída desejada da SVM, fixando o parâmetro C em 10.000, e validação cruzada *leave-one-out* para a série D do voluntário I. A taxa de acerto média foi de 88,2%, pode-se perceber que para o movimento EP que representa Extensão do Punho, o erro foi devido ao fato de que a rede acreditou se tratar do movimento

RAC, Rotação do Antebraço e Contração da Mão. Outro movimento em que ocorreu o reconhecimento incorreto foi o RA (Rotação do Antebraço) com FA (Flexão do Antebraço)



**Figura 34 Saída da SVM para o Voluntário I, executando a série D.**

#### 4.2.2 Voluntário II

Para o Voluntário II, foram utilizados somente 7 canais, uma vez que o Canal 2 (Flexor Radial do Carpo) encontrava-se sem sinal durante parte dos ensaios. Utilizou-se as mesmas seis características (RMS, média, variância, desvio padrão, *skewness*, *kurtosis*). De forma aleatória foi selecionada a série B.

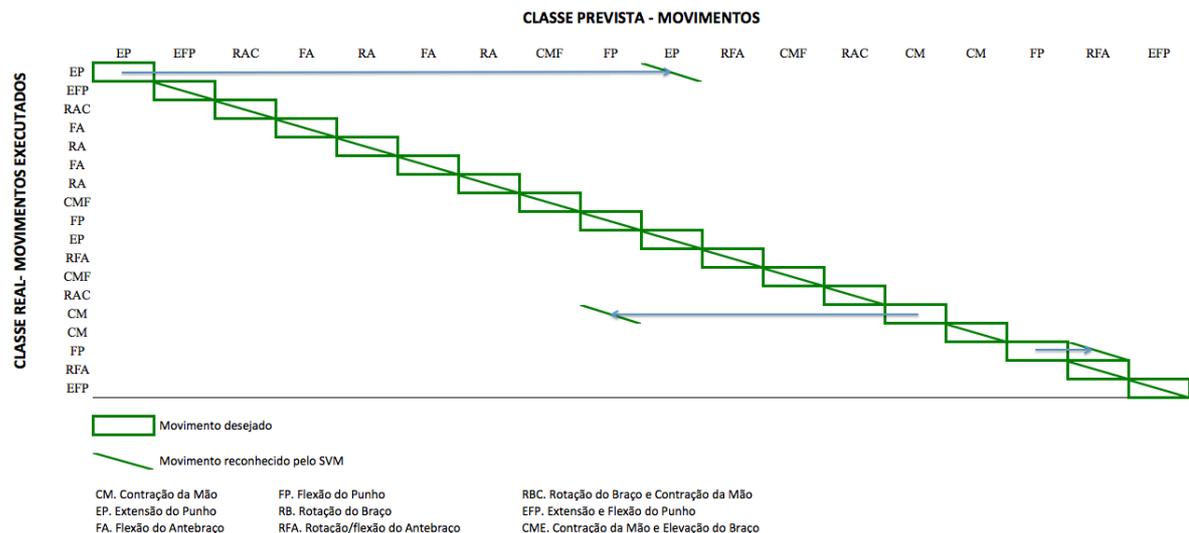
A Tabela 18 apresenta os resultados, da taxa de acerto média, obtidos da variação do parâmetro de regularização (C) da SVM, para os métodos *leave-one-out* e *k-fold*.

**Tabela 18 Taxa de acerto média do Voluntário II executando a série B.**

<b>Voluntário II (Série B)</b>	<b>C=100</b>	<b>C=1.000</b>	<b>C=10.000</b>
<b>Leave-one-out</b>	<b>66,7%</b>	<b>83,3%</b>	<b>94,4%</b>
<b>K-fold (k=10)</b>	<b>67,6%</b>	<b>90,4%</b>	<b>100%</b>

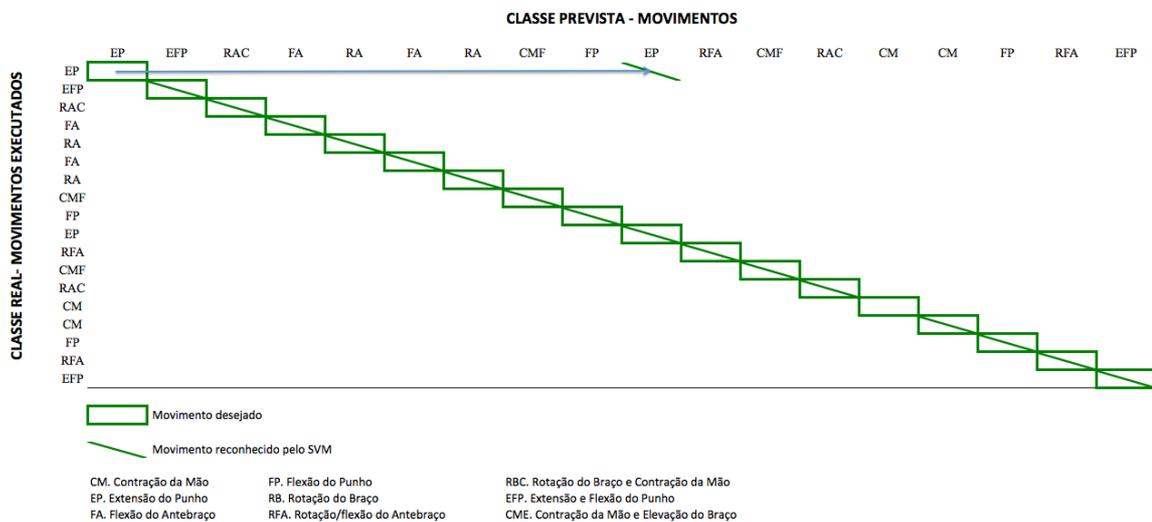
Concluiu-se que o valor do parâmetro de regularização (C) da SVM, que se ajusta pelo resultado da avaliação sob os dados de teste, pode ser ajustado em 1.000, diminuindo o tempo de processamento, pois quanto maior o C, maior o tempo de processamento da SVM. O método *k-fold* apresentou, em todos os testes, uma taxa de acerto média mais elevada que *leave-one-out*.

A Figura 35 representa a saída real e a saída desejada da SVM, fixando o parâmetro C em 1.000, e validação cruzada *leave-one-out* para a série B do voluntário II. A taxa de acerto média foi de 83,3%, pode-se perceber que para o movimento EP (Extensão do Punho) o reconhecimento incorreto foi devido ao fato de que a rede entendeu se tratar do próprio movimento EP (Extensão do Punho) o que não pode ser considerado erro uma vez que o movimento aparece duas vezes na série. A CM (Contração da Mão) foi confundida com a FP (Flexão do Punho). Outro movimento em que ocorreu o reconhecimento incorreto foi a FP (Flexão do Punho) com RFA (Rotação e Flexão do Antebraço).



**Figura 35 Saída da SVM para o Voluntário II, executando a série B.**

A Figura 36 representa a saída real e a saída desejada da SVM, fixando o parâmetro C em 10.000, e validação cruzada *leave-one-out* para a série B do voluntário II. A taxa de acerto média foi de 94,4%, pode-se perceber que para o movimento EP (Extensão do Punho) o reconhecimento incorreto foi devido ao fato de que a rede entendeu se tratar do próprio movimento EP (Extensão do Punho) o que não pode ser considerado erro uma vez que o movimento aparece duas vezes na série.



**Figura 36 Saída da SVM para o Voluntário II, executando a série B.**

O caso particular das Figuras 35 e 36 apresenta o acerto da SVM para o movimento EP apenas na segunda repetição, provavelmente o movimento EP apresenta características distintas e significativas na primeira e segunda repetição na série B, porém dentro de uma margem aceitável para reconhecer o movimento como EP.

### 4.3 VARIANDO AS CARACTERÍSTICAS UTILIZADAS

Para avaliar a relação entre as características e a taxa de acertos foram utilizados os sinais adquiridos do Voluntário I, em oito canais, retirando apenas uma determinada característica em cada análise.

O parâmetro de regularização (C) da SVM foi ajustado baseado nos resultados dos dados de teste. Dois métodos de validação foram utilizados para avaliar a taxa de acerto média, *leave-one-out* e *k-fold*, variando o parâmetro de regularização (C) da SVM em 100, 1.000 e 10.000.

#### 4.3.1 Análise sem RMS

Para processar o sinal na SVM utilizou-se 5 características (variância, desvio padrão, média, *kurtosis* e *skewness*) obtidas a partir dos vetores que contém o sinal segmentado de cada canal.

Na Tabela 19 encontra-se a taxa de acerto média, sem RMS, variando C e o método de validação cruzada do Voluntário I executando a série D.

**Tabela 19 Taxa de acerto média sem RMS.**

<b>Voluntário I (Série D)</b>	<b>C=100</b>	<b>C=1.000</b>	<b>C=10.000</b>
<b>Leave-one-out</b>	<b>58,8%</b>	<b>82,4%</b>	<b>88,2%</b>
<b>K-fold (k=10)</b>	<b>64,6%</b>	<b>85,8%</b>	<b>91,2%</b>

Concluiu-se que variando o valor do parâmetro C de 100 para 1.000, houve grande aumento na taxa de acerto média dos movimentos, e manteve-se praticamente o mesmo índice na taxa de acertos na variação de 1.000 para 10.000 do parâmetro C, quando retirou-se os valores RMS das características. Se comparados com os dados obtidos na Tabela 17, em que o RMS participava dos dados, pode-se observar que para C=100, o qual apresenta um tempo de processamento menor, notou-se um aumento significativo na taxa de acerto média de

58,8% para 76,5% no método *leave-one-out*, e de 64,6% para 76,5% no método *k-fold*. Para C igual 1.000 e 10.000 a taxa de acerto manteve-se praticamente igual, com ou sem o RMS.

#### 4.3.2 Análise sem *Kurtosis*

Foram utilizadas 5 características (RMS, média, variância, desvio padrão e *skewness*) obtidas a partir dos vetores que contém o sinal segmentado de cada canal.

Na Tabela 20 encontra-se a taxa de acerto média, sem *kurtosis*, variando C e o método de validação cruzada do Voluntário I executando a série D.

**Tabela 20 Taxa de acerto média sem a *kurtosis*.**

<b>Voluntário III (Série E)</b>	<b>C=100</b>	<b>C=1.000</b>	<b>C=10.000</b>
<b>Leave-one-out</b>	<b>35,3%</b>	<b>52,9%</b>	<b>64,7%</b>
<b>K-fold (k=10)</b>	<b>36,6%</b>	<b>71,7%</b>	<b>76,8%</b>

Concluiu-se que aumentando o valor do parâmetro C, houve um expressivo aumento na taxa de acerto média quando retirou-se os valores de *kurtosis* das características. Assim, para manter uma taxa de acerto alta o C deve ser fixado em 10.000, no entanto, mesmo operando em oito canais, o tempo de processamento mostrou-se elevado. Se comparados com os dados obtidos na Tabela 17, na qual a *kurtosis* participava dos dados, pode-se observar a diminuição acentuada na taxa de acerto média para todos os valores de C. O método *k-fold* continuou apresentando, em todos os testes, uma taxa de acerto média mais elevada que *leave-one-out*.

#### 4.3.3 Análise sem *Skewness*

Para o Voluntário I foram utilizados 5 características (RMS, média, variância, desvio padrão e *kurtosis*) obtidas a partir dos vetores que contém o sinal segmentado de cada canal.

Na Tabela 21 encontra-se a taxa de acerto média, sem *skewness*, variando C e o método de validação cruzada do Voluntário I executando a série D.

**Tabela 21 Taxa de acerto média sem a *skewness*.**

<b>Voluntário I (Série D)</b>	<b>C=100</b>	<b>C=1.000</b>	<b>C=10.000</b>
<b>Leave-one-out</b>	<b>41,2%</b>	<b>64,7%</b>	<b>88,3%</b>
<b>K-fold (k=10)</b>	<b>45,3%</b>	<b>70,4%</b>	<b>90,0%</b>

Concluiu-se que variando o valor do parâmetro de regularização (C) da SVM, houve grande variação da taxa de acerto média quando retirou-se os valores da *skewness* das características. Se comparados com os dados obtidos na Tabela 17, na qual a *skewness* participava dos dados, pode-se observar que diminuiu muito a taxa de acerto média para todos os valores de C em 100 e 1.000, mantendo-se praticamente os mesmos em 10.000. O método *k-fold* apresentou, em todos os testes, uma taxa de acerto média mais elevada que *leave-one-out*.

#### 4.3.4 Análise sem Variância

Utilizou-se 5 características (RMS, média, desvio padrão, *kurtosis* e *skewness*), obtidas a partir dos vetores que contém o sinal segmentado de cada canal, para processar o sinal na SVM.

Na Tabela 22 encontra-se a taxa de acerto média, sem variância, variando C e o método de validação cruzada do Voluntário I executando a série D.

**Tabela 22 Taxa de acerto média sem a variância.**

<b>Voluntário I (Série D)</b>	<b>C=100</b>	<b>C=1.000</b>	<b>C=10.000</b>
<b>Leave-one-out</b>	<b>52,9%</b>	<b>58,8%</b>	<b>58,8%</b>
<b>K-fold (k=10)</b>	<b>53,8%</b>	<b>66,8%</b>	<b>67,8%</b>

Concluiu-se que aumentando o valor do parâmetro C, houve pouca variação na taxa de acerto média quando retirou-se os valores da variância das características, havendo uma pequena diferença de 100 a 1.000 e mantendo-se praticamente constante de 1.000 a 10.000, além de manter uma taxa de acerto média baixa. Se comparados com os dados obtidos na Tabela 16, em que a variância participava dos dados, pode-se observar que diminuiu muito a taxa de acerto média para todos os valores de C. O método *k-fold* apresentou, em todos os testes, uma taxa de acerto média mais elevada que *leave-one-out*.

#### **4.4 COMPARAÇÃO DOS RESULTADOS DESTE TRABALHO COM OUTROS ESTUDOS**

Para se obter uma comparação adequada é necessário conhecer os movimentos executados, o número de canais, as características e o classificador utilizado, sem desconsiderar a dificuldade em confrontar determinados trabalhos com outros e a importância de estudos continuados nesta área.

Os sistemas desenvolvidos por FAVIEIRO, 2012, e BERMUDEZ, 2013, foram apresentados de forma similar ao estudo proposto neste trabalho. FAVIEIRO, 2012, utilizou a

técnica *neuro-fuzzy* para classificar 12 movimentos distintos, utilizando 8 canais de aquisição do sinal e o valor RMS, como característica de cada canal, obtendo uma taxa de acerto de 65%. BERMUDEZ, 2013, utilizou 8 canais, 6 características e Rede Neural para classificar 9 movimentos com uma taxa de acerto médio de 63%. O estudo proposto neste trabalho utilizou uma SVM para classificar 9 movimentos distintos utilizando 6 características de cada canal, obtendo uma taxa de acerto de 83,2 % para dois canais e 91,3% para oito canais.

Comparando o sistema desenvolvido com Classificador SVM, SHENOY, 2011, classificou 6 movimentos simples da mão, utilizando somente dois canais e como característica o valor RMS. No final do processo obteve uma taxa de acerto média de 96%. Também foi desenvolvido um sistema por BOSCHMANN e PLATZNER, 2012, para caracterizar 11 classes de movimentos da mão e do punho, utilizando 96 canais, obtendo uma taxa de acerto média de 86%.

É importante salientar que o estudo proposto variou o valor do C, parâmetro de regularização da SVM, provando que há diferentes taxas de acertos quando é alterado o tempo de processamento, bem como utilizou dois métodos de classificação, metodologia não encontrada em nenhum outro trabalho.

## 5 CONCLUSÕES

O sistema proposto apresentava como objetivos a avaliação da relação entre o número de canais de classificação com a taxa de acertos, a relação entre o número de características com a taxa de acerto, a analogia entre a variação do parâmetro de regularização (C) da SVM com a taxa de acertos e a comparação de dois métodos de validação cruzada, *leave-one-out* e *k-fold*.

No final dos testes, observou-se que, ampliando o número de canais, aumentou-se a taxa de acerto dos movimentos. Retirando determinada característica, houve diminuição na taxa de acerto do sistema. Aumentado o valor de C, elevou-se o custo e criou um modelo mais preciso. Outra conclusão importante apresenta-se quando aumentado o número de canais pode-se diminuir o parâmetro de regularização (C) da SVM, e, em consequências diminuir o custo. O método *k-fold* apresentou, em todos os testes, uma taxa de acerto média mais elevada que o *leave-one-out*. A taxa de acerto média obtida foi de 83,2 % para dois canais, e 91,3% para oito canais com 9 movimentos distintos, considerando  $C=10.000$  e validação cruzada *leave-one-out*.

Certas falhas levaram ao decréscimo da taxa de acerto do sistema para determinados movimentos. Dentre elas pode-se citar que: alguns voluntários, durante os ensaios, realizaram os movimentos de forma errônea ou incompleta; durante o ensaio, determinado canal pode ter sido descartado por estar sem sinal ativo, durante determinado período de tempo do ensaio, ou com muito ruído, ou ainda sem sinal de EMG, devido principalmente ao descolamento do eletrodo em função dos movimentos executados ou simplesmente a perda do contato entre o eletrodo e a pele; alguns movimentos foram desconsiderados, pelo programa, por estar abaixo do limiar ao executar a segmentação do sinal.

## 6 PROPOSTA PARA TRABALHOS FUTUROS

No desenvolvimento deste trabalho notou-se a necessidade de se obter uma amostragem mais representativa dos dados, analisando ensaios com um número maior de voluntários, incluindo pessoas com amputação parcial e/ou total do segmento mão-braço. Além de acrescentar, para trabalhos posteriores, características que poderiam ser extraídas do sinal de EMG, bem como aumentar o número de canais, a fim de melhorar o desempenho da SVM, diminuindo o tempo de processamento e mantendo uma elevada taxa de acertos dos movimentos.

Outro avanço importante do sistema seria realizar testes comparativos com SVM's não lineares. Assim como apresentar um estudo mais aprofundado na abordagem do tempo de processamento ou parâmetro de custo, e nas técnicas de *cross-validation*, acrescentando a técnica *holdout* (retenção) nos testes comparativos.

Desenvolvimento e estudo de um Projeto de Experimento para análise estatística dos resultados obtidos neste trabalho, assim como uma análise e desenvolvimento de um sistema realimentado, permitindo a redução do erro experimental, como por exemplo, nos casos de execução de movimento de forma errada ou incompleta e com níveis de força diferentes.

## REFERÊNCIAS

- ATZORI, M. et al. Building the Ninapro database: A resource for the biorobotics community. In: INTERNATIONAL CONFERENCE ON BIOMEDICAL ROBOTICS AND BIOMECHATRONICS (BioRob), 4., 2012, Rome. Proceedings...[S.l.]:IEEE, 2012. p.1258-1265.
- BALBINOT, A. et al. Desenvolvimento de uma Prótese experimental controlada por eletromiografia. In: CONGRESSO IBERO-AMERICANO SOBRE TECNOLOGIAS DE APOIO A PORTADORES DE DEFICIÊNCIA, 4., 2006, Vitória. Anais... Vitória: IBERDISCAP, 2006. v.1, MA-3 – MA-6.
- BALBINOT, A.; FAVIERO, G. A Neuro-Fuzzy System for Characterization of Arm Movements. Journal sensors, Basel, n.13, p. 2613-2630, 21 Feb. 2013.
- BASMAJIAN, J.V.; DE LUCA, C.J. Muscle alive: their functions revealed by electromyography. Baltimore: Williams & Wilkins, 1985.
- BEMUDEZ, R. Proposta de um sistema baseado em redes neurais e wavelets para caracterização de movimentos do segmento mão-braço. 2013. 112p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2013.
- BOSCHMANN, A. et al. Towards multi-movement hand prostheses: combining adaptive classification with high precision sockets. In: EUROPEAN CONFERENCE TECHNICALLY ASSISTED REHABILITATION, 2nd, Berlin. Proceedings... [S.l. : s.n.], 2009. p. 18–19.
- CABENA, P. et al. Discovering data mining: From concept to implementation. Upper Saddle River: Prentice Hall, 1997.
- CAWLEY, G. C. Leave-one-out cross-validation based model selection criteria for weighted ls-svms. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN 2006), 2006, Vancouver. Proceedings...[S.l.]: IEEE, 2006. p. 1661–1668.
- CHAGAS, S. L. Classificação de Sinais de Eletroencefalograma usando Máquinas de Vetores Suporte. 2009. 85 p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Presbiteriana Mackenzie, São Paulo, 2009.
- CHRISTODOULOU, C. I. ; PATTICHIS, C. S. A new technique for the classification and decomposition of EMG signals. In: IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, 1995, Perth. Proceedings...[S.l.]: IEEE, 1995. vol. 5, p. 2303.2308.
- CLEMENTE, S. C. R. Aplicação da transformada de wavelet–família daubechies 12 no estudo da síncope vasovagal. 2008. 92p. Dissertação (Mestrado em Biofísica) – Universidade de Lisboa, Lisboa, 2008.
- CONTO, E.; BALBINOT, A. Ambientes virtuais controláveis por sinais mioelétricos. In: SALÃO DE INICIAÇÃO CIENTÍFICA DO IC/FUC, 15. 2011, Porto Alegre. Anais... Porto Alegre: FUC, 2011, p. 1-4.

- FAVIERO, 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.
- FAVIEIRO, G. Controle de uma prótese experimental do segmento mão-braço por sinais mioelétricos e redes neurais artificiais. 2009. 111 f. Trabalho de conclusão de curso (Graduação em Engenharia de computação) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009.
- GUYTON, A. C. Fisiologia Humana. 6. ed. Rio de Janeiro: Guanabara Koogan, 1988.
- HAYKIN, S. Redes Neurais: princípios e prática. 2. ed. Porto Alegre: Bookman, 1999.
- HSU, C.-W; CHANG, C.-C.; LIN, C.-J. A Practical Guide to Support Vector Classification. Disponível em: <<http://www.csie.ntu.edu.tw/~cjlin/libsvm>> Acesso em: 15 jun. 2013.
- KAUR, G.; ARORA, A. S.; JAIN, V. K. Comparison of the techniques used for segmentation of EMG signals. In: INTERNATIONAL CONFERENCE ON MATHEMATICAL AND COMPUTATIONAL METHODS IN SCIENCE AND ENGINEERING (MACMESE'09), 11., 2009, Stevens Point. Proceedings... [S.l. : s.n.], 2009, p.124-129.
- LEIS, A. A.; TRAPANI, V. C. Atlas of Electromyography. Oxford: Oxford, Incorporated, 2000.
- LIU, H.; HUANG, Y.-W.; LIU, D. Multi-class surface EMG classification using support vector machines and wavelet transform. In: WORLD CONGRESS ON INTELLIGENT CONTROL AND AUTOMATION (WCICA), 8., 2010, Jinan. Proceedings... [S.l.]: IEEE, 2010. p. 2963 – 2967.
- LORENA, A. C.; DE CARVALHO A. C. P. L. F. Introdução às Máquinas de Vetores Suporte (Support Vector Machines). São Carlos: USP, 2003. Relatório Técnico do ICMC.
- MAZURKIEWICZ, P. Automatic segmentation of emg signals based on wavelet representation. In: KURZYNSKI, M. et al. Computer recognition systems 2. ed. Wybrzeze: Springer, 2007. p. 589-595.
- ORTOLAN, R. L. Estudo e avaliação de técnicas de processamento do sinal mioelétrico para o controle de sistemas de reabilitação. 2002. 117 p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade de São Paulo, São Carlos, 2002.
- PATTEN, J. Diagnostico diferencial em neurologia. 2. ed. Rio de Janeiro : Revinter, 2000.
- RICCIOTTI, A. C. D. Utilização de Wavelets no processamento de sinais EMG. 2006. 57p. Dissertação (Mestrado em Ciências) – Universidade Federal de Uberlândia, Uberlândia, 2006.
- SENIAN. Disponível em: <<http://www.seniam.org/>> Acesso em: 05 mar. 2013.
- SHAWE-TAYLOR, J.; CRISTIANINI, N. An Introduction to Support Vector Machines and Other Kernel-based Learning Methods. [S.l.]: Cambridge, 2000.

SHENOY, P. et al. Online electromyographic control of a robotic prosthesis. *IEEE Biomedical Engineering*, [S.l.], v. 55, n.3, p.1128–1135, Mar. 2008.

SOBOTTA, J. *Atlas de anatomia humana*. 20.ed. Rio de Janeiro: Guanabara Koogan, 1995.

TORTORA, G. J. *Corpo humano: Fundamentos de anatomia e fisiologia*. 4. ed. Porto Alegre: Artmed, 2000.

YONGJIAN, Z. BOGIANG, L. A novel blind source extraction method for biomedical signals. In: *INTERNATIONAL CONFERENCE ON BIOINFORMATICS AND BIOMEDICAL TECHNOLOGY (ICBBT)*, 2010, Chengdu. *Proceedings...* [S.l.]:IEEE, 2010. p. 348 – 352.