



**RECONHECIMENTO DE GESTOS DE MEMBROS SUPERIORES  
USANDO ELETROMIOGRAFIA DE SUPERFÍCIE PARA USO EM  
REABILITAÇÃO**

**LUCAS FERNANDES AGUIAR**

**DISSERTAÇÃO DE MESTRADO EM ENGENHARIA DE SISTEMAS  
ELETRÔNICOS E DE AUTOMAÇÃO  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**FACULDADE DE TECNOLOGIA  
UNIVERSIDADE DE BRASÍLIA**



UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

**RECONHECIMENTO DE GESTOS DE MEMBROS SUPERIORES  
USANDO ELETROMIOGRAFIA DE SUPERFÍCIE PARA USO EM  
REABILITAÇÃO**

**UPPER LIMB GESTURES RECOGNITION USING SURFACE  
ELECTROMYOGRAPHY FOR USE IN REHABILITATION**

**LUCAS FERNANDES AGUIAR**

**ORIENTADOR: ANTÔNIO PADILHA LANARI BÓ**

DISSERTAÇÃO DE MESTRADO EM ENGENHARIA DE  
SISTEMAS ELETRÔNICOS E DE AUTOMAÇÃO

PUBLICAÇÃO: PPGEA.675/2017 MD

BRASÍLIA/DF: AGOSTO - 2017

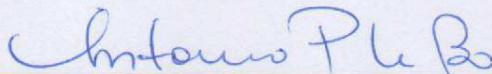
**UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**RECONHECIMENTO DE GESTOS DE MEMBROS SUPERIORES  
USANDO ELETROMIOGRAFIA DE SUPERFÍCIE PARA USO EM  
REABILITAÇÃO**

**LUCAS FERNANDES AGUIAR**

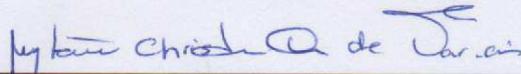
DISSERTAÇÃO DE MESTRADO SUBMETIDA AO DEPARTAMENTO DE ENGENHARIA ELÉTRICA DA FACULDADE DE TECNOLOGIA DA UNIVERSIDADE DE BRASÍLIA, COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE.

APROVADA POR:



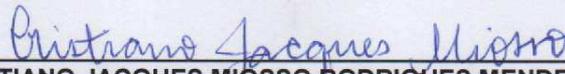
---

ANTÔNIO PADILHA LANARI BÓ, Dr., ENE/UNB  
(ORIENTADOR)



---

MYLENE CHRSTINE QUEIROZ DE FARIAS, Dra., ENE/UNB  
(EXAMINADORA INTERNA)



---

CRISTIANO JACQUES MIOSSO RODRIGUES MENDES Dr., FGA/UNB  
(EXAMINADOR EXTERNO)

Brasília, 22 de agosto de 2017.

## FICHA CATALOGRÁFICA

LUCAS, FERNANDES AGUIAR

RECONHECIMENTO DE GESTOS DE MEMBROS SUPERIORES USANDO ELETROMIOGRAFIA DE SUPERFÍCIE PARA USO EM REABILITAÇÃO [Distrito Federal] 2017.

xi+100 p., 210 x 297 mm (ENE/FT/UnB, Mestre, Engenharia de Sistemas Eletrônicos e de Automação, 2017).

DISSERTAÇÃO DE MESTRADO – Universidade de Brasília, Faculdade de Tecnologia.

Departamento de Engenharia Elétrica

1. Reconhecimento de pose

2. Eletromiografia

3. Treinamento

4. Classificação

I. ENE/FT/UnB

II. Título (série)

## REFERÊNCIA BIBLIOGRÁFICA

LUCAS, F. A. (2017). RECONHECIMENTO DE GESTOS DE MEMBROS SUPERIORES USANDO ELETROMIOGRAFIA DE SUPERFÍCIE PARA USO EM REABILITAÇÃO, DISSERTAÇÃO DE MESTRADO, Publicação PPGA.675/2017 MD, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília, DF, xi+100.

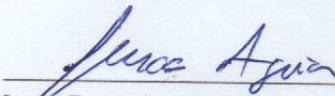
## CESSÃO DE DIREITOS

AUTOR: Lucas Fernandes Aguiar

TÍTULO: RECONHECIMENTO DE GESTOS DE MEMBROS SUPERIORES USANDO ELETROMIOGRAFIA DE SUPERFÍCIE PARA USO EM REABILITAÇÃO.

GRAU: Mestre ANO: 2017

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa dissertação de mestrado pode ser reproduzida sem autorização por escrito do autor.

  
\_\_\_\_\_  
Lucas Fernandes Aguiar

Departamento de Eng. Elétrica (ENE) - FT  
Universidade de Brasília (UnB)  
Campus Darcy Ribeiro  
CEP 70919-970 - Brasília - DF - Brasil

*à meus familiares e amigos e àqueles que  
possam se beneficiar com tecnologias para  
reabilitação.*

## **AGRADECIMENTOS**

*Este trabalho demandou muito esforço e dedicação, agradeço ao meu orientador, prof. Dr. Antônio Padilha pelo direcionamento e apoio. Agradeço também à secretaria de pós-graduação da Engenharia Elétrica e seus funcionários. Sou muito grato pelo suporte oferecido pela minha família em todas as minhas empreitadas acadêmicas e profissionais, em especial aos meus pais Raimundo Aguiar e Cleida Fernandes. Agradeço pela paciência da minha namorada, Solange. Agradeço a Deus e meus amigos da MERT pelo companheirismo. Por fim, agradeço ao colega Luiz Figueredo pela disponibilização do modelo Lyx para formatação da dissertação.*

## RESUMO

**Título:** Reconhecimento de gestos de membros superiores usando eletromiografia de superfície para uso em reabilitação

**Autor:** Lucas Fernandes Aguiar

**Orientador:** Antônio Padilha Lanari Bó

Tecnologias vestíveis são um dos focos de estudo da computação ubíqua, que por sua vez está na vanguarda do recente paradigma da computação em que um usuário está cercado por diversos dispositivos computacionais. As áreas de cuidados para a saúde e reabilitação vêm sendo estimuladas por novas tecnologias vestíveis surgindo no mercado e por pesquisas acadêmicas conduzidas mundialmente. Este trabalho se insere justamente neste contexto com o uso de um dispositivo vestível para obtenção de dados de eletromiografia de superfície para o desenvolvimento de uma tecnologia de reconhecimento de gestos de mão e propondo um algoritmo inovador para clusterização, treinamento e classificação multi classe.

Terapias de reabilitação de movimento de membro superior que utilizam gestos do membro contralateral necessitam de métodos eficientes, rápidos e de fácil configuração para reconhecimento de gestos que possam ser utilizados em interfaces inteligentes, para a estimulação do membro parético, fazendo uso da imagética motora que resulta no movimento do membro saudável como estratégia de terapia para o membro lesionado. O objetivo deste trabalho é aplicar um sistema de aquisição de eletromiografia (EMG) multicanal econômico e de fácil utilização, bem como avaliar seu desempenho de reconhecimento de gestos em um protocolo onde nenhum procedimento de inicialização seja necessário antes do uso.

Dados de EMG do antebraço gerados a partir do movimento das mãos são analisados de forma a extrair a informação mais relevante para a classificação de gestos previamente determinados. Um algoritmo é apresentado e se utiliza um arranjo das ferramentas, iniciando com a análise das componentes principais (PCA) para selecionar as características mais relevantes que foram extraídas do sinal de EMG, clusterização por k-means utilizando os dados projetados sobre suas componentes principais com o objetivo de encontrar os centróides que representem as regiões de cada gesto, árvore binária multimodal (MBT) de forma a permitir que o problema de classificação multi modal fosse particionado em problemas menos complexos, e máquina de vetor de suporte (SVM) como metodologia para separação binária de classes, todas estas técnicas combinadas de maneira a aprimorar o treinamento e classificação do reconhecedor.

O classificador de 5 gestos criado com tal metodologia apresenta taxa de acerto média de 81% em tempo real, demonstrando potencial para investigação futura em aplicações de interface baseada em dados de sEMG, bem como em reabilitação. Já o classificador de 9 gestos apresenta taxa média de acerto de 46%, o que mostra que este reconhecedor necessita de mais dados para esta tarefa devido à similaridade dos dados de EMG entre eles.



# ABSTRACT

**Title:** Upper limb gestures recognition using surface electromyography for use in rehabilitation

**Author:** Lucas Fernandes Aguiar

**Supervisor:** Antônio Padilha Lanari Bó

Wearable technologies are on the center of ubiquitous computing researches, which is leading to a new paradigm where one user is surrounded by many computational devices. Healthcare and rehabilitation are being aroused by new wearable devices available on the market and by academic researches conducted worldwide on this field. This work is precisely inserted in this topics by using a wearable gadget to obtain superficial electromyography data in order to develop a hand gesture recognition technology and proposing a novel algorithm for clustering, training and classification for multi-class problems.

Upper limb movement rehabilitation therapies using contralateral limb gestures require efficient, quick, and easily configured methods for recognizing gestures that can be used in intelligent interfaces for the stimulation of the paretic limb, making use of motor imagery that results in the movement of the healthy limb as a therapy strategy for the injured limb. The goal of this work is to apply an easy-to-use and economical multi-channel electromyography (EMG) acquisition system and evaluate its gesture recognition performance in a protocol where no initialization procedure is allowed before use

Forearm EMG data generated from hand movement are analyzed in order to extract the most relevant information for the classification of previously determined gestures. An algorithm is presented and an array of tools is used, starting with the main component analysis (PCA) to select the most relevant characteristics that were extracted from the EMG signal, k-means clustering using the projected data on its main components aiming to find the centroids that represent the regions of each gesture, a multi-modal binary tree (MBT) in order to allow the problem of multi-modal classification to be partitioned into less complex problems, and support vector machine (SVM) as methodology for binary class separation, all these techniques combined in a way to improve the training and classification of the recognizer.

The 5-gesture classifier created with such methodology presents a real-time average hit rate of 81%, demonstrating the potential for future research in interface applications based on sEMG data, as well as in rehabilitation. On the other hand, the 9-gesture classifier has a 46% hit rate, which means that this classifier needs more data to distinguish gestures with similar sEMG data.

## SUMÁRIO

---

<b>1</b>	<b>INTRODUÇÃO</b>	<b>1</b>
1.1	CONTEXTUALIZAÇÃO	1
1.1.1	COMPUTAÇÃO UBÍQUA E DISPOSITIVOS VESTÍVEIS	1
1.1.2	REABILITAÇÃO DE MEMBRO SUPERIOR	2
1.2	DEFINIÇÃO DO PROBLEMA	3
1.3	OBJETIVOS	4
1.4	PRINCIPAIS CONTRIBUIÇÕES	4
1.5	ORGANIZAÇÃO DO MANUSCRITO	4
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>5</b>
2.1	INTERAÇÃO HOMEM-MÁQUINA	5
2.2	REABILITAÇÃO ASSISTIDA POR COMPUTADOR	6
2.3	RECONHECIMENTO DE GESTOS DE MEMBRO SUPERIOR	8
2.4	AQUISIÇÃO DE SINAIS FISIOLÓGICOS	8
2.4.1	SENSOR DE EMG	10
2.5	MYO ARMBAND	11
2.6	EXTRAÇÃO DE CARACTERÍSTICAS	13
2.6.1	CARACTERÍSTICAS DO EMG	13
2.6.2	TÉCNICAS SUPERVISIONADAS E NÃO-SUPERVISIONADAS	14
2.7	ANÁLISE DE COMPONENTES PRINCIPAIS	15
2.8	CLASSIFICAÇÃO	19
2.8.1	CLASSIFICAÇÃO DO MOVIMENTO HUMANO	19
2.8.2	K-MEANS	19
2.8.3	CLASSIFICADORES BINÁRIOS ESTENDIDOS PARA MULTI CLASSE	21
2.8.4	MULTI-MODAL BINARY TREE (MBT)	22
2.8.5	MÁQUINA DE VETOR DE SUPORTE (SVM)	22
<b>3</b>	<b>RECONHECIMENTO DE GESTOS</b>	<b>24</b>
3.1	DEFINIÇÃO DOS GESTOS DE MÃO	24
3.2	ETAPAS DO PROJETO	24
3.3	OBTENÇÃO DOS DADOS	27
3.4	PRÉ-PROCESSAMENTO	28
3.5	EXTRAÇÃO DE CARACTERÍSTICAS	29
3.6	SELEÇÃO DE CARACTERÍSTICAS	30
3.7	CLUSTERIZAÇÃO	37
3.8	TREINAMENTO	42
3.8.1	CLASSIFICADORES BINÁRIOS	43
3.9	CLASSIFICAÇÃO	48
3.10	CONCLUSÃO	51
<b>4</b>	<b>TESTES DE DESEMPENHO</b>	<b>52</b>
4.1	METODOLOGIA	52

<i>SUMÁRIO</i>	ii
4.2 RESULTADOS.....	52
<b>5 CONCLUSÃO .....</b>	<b>55</b>
5.1 CONSIDERAÇÕES FINAIS .....	55
5.2 TRABALHOS FUTUROS.....	56
<b>BIBLIOGRAFIA.....</b>	<b>57</b>
<b>A SVMS PARA 9 GESTOS.....</b>	<b>62</b>
<b>B FEATURES PARA 5 GESTOS.....</b>	<b>66</b>
<b>C FEATURES PARA 9 GESTOS.....</b>	<b>71</b>

## LISTA DE FIGURAS

---

1.1	Categoria de informação que o consumidor de tecnologias vestíveis deseja receber (Fonte: HRI/CIS Wearables consumer survey 2014).....	2
2.1	Bracelete myo armband utilizado neste trabalho para medição de sinais de EMG do antebraço por 8 canais. ....	11
2.2	Funcionalidades nativas do myo armband. (1) leitura de aceleração linear. (2) toque duplo ( <i>double-tap</i> ). (3) punho fechado ( <i>fist</i> ). (4) dedos abertos ( <i>fingers spread</i> ). (5) mão para dentro ( <i>wave in</i> ). (6) mão para fora ( <i>wave out</i> ). (7) leitura de velocidade angular. ....	12
2.3	Dados originais e pré-processados antes do procedimento de exemplo de PCA. ....	16
2.4	Dados e componentes principais após o procedimento de exemplo de PCA. ....	17
2.5	Dados projetados sobre a componente principal de maior rank obtidos através da técnica de PCA de exemplo. ....	18
2.6	Dados agrupados em dois clusters através do método k-mean mostrando os clusters e os centróides. ....	21
2.7	Árvore binária formada pelo classificador do tipo “um contra resto” para a separação de cinco classes realizada por no máximo quatro testes. ....	22
2.8	SVM linear. ....	23
3.1	Gestos de mão utilizados neste projeto. Cada gesto representa uma classe a ser treinada no classificador. ....	25
3.2	Etapas da fase de treinamento. A etapa inicial da fase de treinamento é a captura dos dados marcados. As iterações de captura, análise e armazenamento dos dados marcados é realizada com várias pessoas. Ao fim das iterações inicia-se a etapa de treinamento. ....	26
3.3	Etapas da fase de classificação. A etapa inicial da fase de classificação é a captura de novos dados. Assim que chegam os novos dados são analisados, classificados e uma classe é assinalada como resultado. ....	26
3.4	EMG extraído pelo Myo através de 8 canais independentes normalizado entre -1 e 1. ....	27
3.5	Diagrama da etapa de pré-processamento. Uma vez que o wrapper do myo já entrega os dados normalizados, esta etapa consiste simplesmente no janelamento temporal dos dados. ....	28
3.6	Janelamento temporal de EMG com sobreposição das janelas. As janelas compartilham parte da informação. ....	28
3.7	Janelamento temporal de EMG sem sobreposição das janelas. As janelas não compartilham nenhuma parte da informação. ....	28
3.8	Dados de três movimentos projetados sobre as duas componentes principais obtidos pela técnica de PCA. O uso de janelamento com sobreposição com janelas muito próximas gera um rastro que prejudica o processamento dos dados. ....	29
3.9	Característica extraída - Valor RMS para cada janela por canal. Nesta figura é possível visualizar as regiões dos nove gestos. ....	30
3.10	Característica extraída - Envoltória. ....	31
3.11	Característica extraída - Skewness. ....	31
3.12	Diagrama da extração de características. ....	32
3.13	Diagrama da etapa de seleção de características. ....	33
3.14	Contribuição percentual das componentes principais para teste com 5 gestos. ....	34

3.15	Características projetadas sobre as componentes principais 1, 2 e 3. 5 gestos.....	35
3.16	Características projetadas sobre as componentes principais 1 e 2. 5 gestos.....	36
3.17	Resultado da clusterização convencional por k-means para 9 gestos.....	38
3.18	Resultado da clusterização convencional por k-means para 5 gestos.....	38
3.19	Histograma para 5 gestos.....	40
3.20	Resultado do método proposto para clusterização por k-means para 9 gestos.....	41
3.21	Resultado do método proposto para clusterização por k-means para 5 gestos.....	41
3.22	Árvore binária multi modal para 5 gestos. Os testes mais fáceis são realizados inicialmente, os mais complexos no final.....	43
3.23	SVM do teste 1 - descanso contra resto - 5 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	44
3.24	Região da SVM do teste 1 - descanso contra resto - 5 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	44
3.25	SVM do teste 2 - aceno para fora contra resto - 5 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	45
3.26	Região da SVM do teste 2 - aceno para fora contra resto - 5 gestos.....	45
3.27	SVM do teste 3 - aceno para dentro contra resto - 5 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	46
3.28	Região da SVM do teste 3 - aceno para dentro contra resto - 5 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	46
3.29	SVM do teste 4 - punho fechado contra resto - 5 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	47
3.30	Região da SVM do teste 4 - punho fechado contra resto - 5 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	47
3.31	TRIAL 001 - Resultado com erro de classificação devido à passagem por regiões intermediárias.....	48
3.32	TRIAL 001 - Gráfico mostrando erro de classificação devido à passagem por regiões intermediárias. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	49
3.33	TRIAL 002 - Gráfico com resultados do teste aceno para fora contra resto. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	50
3.34	TRIAL 003 - Gráfico com resultados do teste aceno para dentro contra resto. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	50
3.35	TRIAL 004 - Gráfico com resultados do teste punho fechado contra resto. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	51
A.1	SVM do teste 1 - descanso contra resto - 9 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	62
A.2	SVM do teste 2 - aceno para fora contra resto - 9 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	62
A.3	SVM do teste 3 - aceno para dentro contra resto - 9 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	63
A.4	SVM do teste 4 - punho fechado contra resto - 9 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	63
A.5	SVM do teste 5 - chifre contra resto - 9 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	64
A.6	SVM do teste 6 - mão espalmada contra resto - 9 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	64
A.7	SVM do teste 7 - hang loose contra resto - 9 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.....	65

A.8	SVM do teste 8 - legal contra resto - 9 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical....	65
B.1	RMS - 8 canais - 5 gestos.....	66
B.2	Variância - 8 canais - 5 gestos. ....	66
B.3	EMG Integrado - 8 canais - 5 gestos. ....	67
B.4	Skewness - 8 canais - 5 gestos.....	67
B.5	Kurtosis - 8 canais - 5 gestos. ....	68
B.6	Waveform Change - 8 canais - 5 gestos. ....	68
B.7	Zero Crossing - 8 canais - 5 gestos. ....	69
B.8	Active - 8 canais - 5 gestos. ....	69
B.9	Envelope - 8 canais - 5 gestos. ....	70
B.10	RMS e Variância com média zero e normalizadas pelo desvio padrão - 8 canais - 5 gestos. ....	70
C.1	RMS - 8 canais - 9 gestos.....	71
C.2	Variância - 8 canais - 9 gestos. ....	71
C.3	EMG Integrado - 8 canais - 9 gestos. ....	72
C.4	Skewness - 8 canais - 9 gestos.....	72
C.5	Kurtosis - 8 canais - 9 gestos. ....	73
C.6	Waveform Change - 8 canais - 9 gestos. ....	73
C.7	Zero Crossing - 8 canais - 9 gestos. ....	74
C.8	Active - 8 canais - 5 gestos. ....	74
C.9	Envelope - 8 canais - 9 gestos. ....	75
C.10	RMS e Variância com média zero e normalizadas pelo desvio padrão - 8 canais - 9 gestos. ....	75

## LISTA DE TABELAS

---

2.1	Tipo de sensores de sinais fisiológicos e seus respectivos níveis de taxas de medição. ....	9
2.2	Dados originais em duas dimensões antes do procedimento de exemplo de PCA. ....	16
3.1	Contribuição percentual acumulada das componentes principais para um teste com 5 gestos. ....	33
4.1	Resultados dos testes do sujeito 1 - sexo masculino, 25 anos. ....	53
4.2	Resultados dos testes do sujeito 2 - sexo masculino, 54 anos. ....	53
4.3	Resultados dos testes do sujeito 3 - sexo feminino, 24 anos. ....	53
4.4	Resultados dos testes do sujeito 4 - sexo feminino, 50 anos. ....	53
4.5	Resultados dos testes do sujeito 5 - sexo masculino, 23 anos. ....	54
4.6	Resultados finais. ....	54

## LISTA DE SÍMBOLOS

---

### **Acrônimos**

EMG	Eletromiografia
sEMG	Eletromiografia de superfície
A/D	Conversor analógico para digital
SNC	Sistema nervoso central
CAR	Reabilitação auxiliada por computador
BCI	Interface cérebro máquina
IMU	Unidade de medidas inerciais
ML	Aprendizagem de máquina
SVM	Support Vector Machine
PCA	Principle Component Analysis
FES	Functional Electrical Stimulation

## 1.1 CONTEXTUALIZAÇÃO

### 1.1.1 Computação ubíqua e dispositivos vestíveis

Um novo paradigma da computação está ganhando espaço. Se no início da computação grandes computadores eram usados por várias pessoas simultaneamente e hoje vivemos na era em que cada pessoa possui seu computador pessoal, a computação ubíqua apresenta uma nova forma de lidar com tecnologia. Nesta nova concepção de interação homem-máquina cada pessoa está cercada por inúmeros tipos de tecnologias que interagem com o homem sem mesmo que este perceba a sua presença. Sejam tecnologias vestíveis com interação direta com o corpo ou tecnologias presentes nos espaços por onde as pessoas vivem, trabalham, se alimentam ou transitam.

Este novo conceito, também conhecido como computação pervasiva, demanda a capacidade de embarcar sensores, poder computacional - geralmente por meio de microcontroladores, alguma tecnologia de conexão sem fio e bateria. Estes dispositivos precisam ser de baixo consumo energético para que possam estar disponíveis o maior tempo possível, enviar dados de sensores e comandos para outros dispositivos no mesmo ambiente ou para servidores na nuvem e possuir interface amigável aos usuários, com objetivo de ser imperceptível ou natural para o usuário.

Na indústria de saúde (*healthcare*) a computação ubíqua ganha espaço por meio de ambientes médicos inteligentes e monitoramento e diagnóstico remotos automáticos, tecnologias de telemedicina e *homecare* melhorando o dia a dia de pacientes e os tornando mais independentes [1]. O monitoramento de sinais vitais por dispositivos pervasivos versáteis e inovadores vem sobrepondo o uso de métodos manuais. Sistemas eletrônicos de baixo consumo registram e interpretam sinais vitais permitindo a detecção precoce de variadas condições físicas como taquicardia, hipertensão, hipotensão, hipoxemia e hipotermia [2]. Projetos mais inovadores buscam determinar a dieta de um paciente baseado na gravação do som da mastigação [3], ou mesmo utilizar detectores de movimento por infravermelho, sensores magnéticos para portas e sensores de pressão para obter informações sobre atividades e comportamentos como cozinhar, dormir e comer [4, 5].

Em relação às tecnologias vestíveis os pacientes, apesar de interessados nos benefícios, ainda não usam amplamente esses dispositivos. A maioria dos consumidores dos Estados Unidos não querem pagar muito para ter dispositivos vestíveis para a saúde, seja para prevenção ou tratamentos. 68% desses consumidores usaria para coletar dados anonimamente, mas sem a intenção de divulgar para familiares e parentes, conforme pesquisa de 2014 [6]. Dentro os principais interesses dos pacientes que responderam à pesquisa em relação a dispositivos ubíquos vestíveis em geral, coletar e rastrear informações médicas está em segundo lugar, e controlar o ambiente em quinto lugar conforme Figura 1.1.

Importante ressaltar que os dados registrados e transmitidos por dispositivos vestíveis ou sensores de ambiente devem ser armazenados e interpretados por um sistema central de controle, o qual concentra toda a informação relativa ao paciente e seu ambiente fornecendo informação útil para os fornecedores de serviços de saúde, acionando um dispositivo ou avisando uma pessoa - aumentando a temperatura de um quarto caso o ambiente esteja muito frio ou a temperatura do paciente esteja muito baixa, ou avisando uma enfermeira sobre

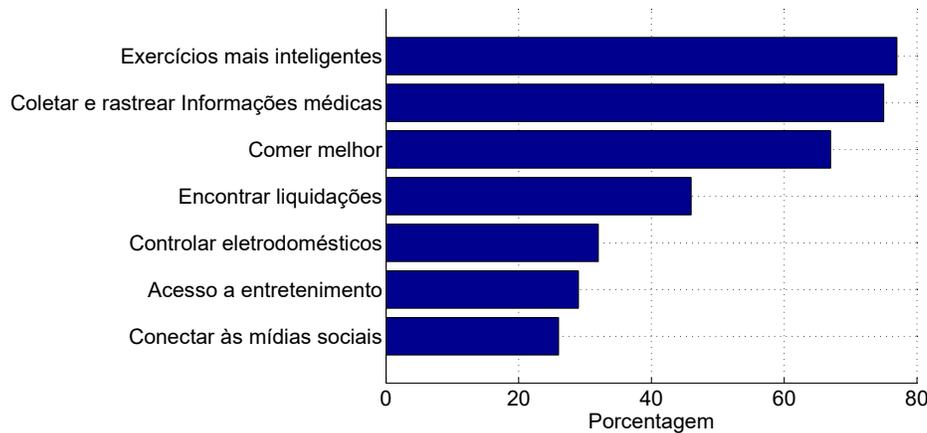


Figura 1.1: Categoria de informação que o consumidor de tecnologias vestíveis deseja receber (Fonte: HRI/CIS Wearables consumer survey 2014).

um pico de glicose por exemplo.

A representação de dados de monitoramento de pacientes por meios gráficos em coordenadas cartesianas, em séries temporais, ou gráficos relacionais necessita de pessoal qualificado que compreenda e saiba traduzir posições, cores e tamanho de gráficos em informação útil. Por meios das tecnologias computacionais de obtenção e processamento integrado de dados é possível desacoplar os dados da representação, ou seja, é possível produzir visualizações relacionais claras e eficientes que incorporem grande densidade de dados de diversos dispositivos [3]. O papel interpretativo antes feito pelos profissionais pode ser desempenhado por algoritmos computacionais.

Outro aspecto a ser considerado quando se trata de dispositivos médicos conectados entre si e à internet é a privacidade da informação e responsabilidade na distribuição e uso dos dados.

## 1.1.2 Reabilitação de membro superior

A falta de mobilidade de membros superiores, causada tanto por acidente vascular cerebral ou outras patologias, podem levar à perda da independência e grave impacto na qualidade de vida, frequentemente devido à incapacidade de executar tarefas rotineiras. No caso de pacientes que apresentem hemiparesia ou hemiplegia, diferentes metodologias de reabilitação podem trazer elevada recuperação funcional. Por este motivo, diversos estudos têm abordado a pesquisa de tipos, dosagem e tempo de terapia.

Entre uma das intervenções terapêuticas mais promissoras para estes pacientes está o treinamento bilateral do braço (BAT), o qual é baseado no movimento simultâneo ou complementar de ambos os braços, com ou sem assistência para o movimento do membro parético. Apesar de já existirem motivações funcionais e neurofisiológicas para tal terapia [7], os estudos ainda não conseguiram comprovar vantagens claras em relação à terapia convencional [8]. Todavia, os avanços recentes das tecnologias vestíveis permitiram a incorporação de novos recursos nestas intervenções, como técnicas de sincronização do movimento através do som, assistência robótica, estimulação elétrica ativada por eletromiografia dos membros paréticos ou pelo movimento dos membros contralaterais. Como esperado, estas adaptações podem levar a diferentes níveis de evolução motora. De fato, uma análise recente indicou que a estimulação neuromuscular ativada por EMG podem levar a resultados

mais efetivos se comparados com movimentos assistidos mecanicamente ou terapia bilateral pura [9].

Ao usar estimulação elétrica funcional (FES) para fornecer o recrutamento muscular necessário para o movimento do membro parético, foram propostas interfaces tanto utilizando sinais de EMG dos membros paréticos quanto o movimento dos membros colaterais. Para aplicações utilizando EMG, um limiar alvo do sinal de EMG do membro parético pode ser utilizado como um gatilho de estimulação de padrão fixo [10]. Entretanto, esta é uma estratégia que não necessariamente melhora a atividade bilateral. O movimento de mão contralateral medido por uma luva instrumentada também foi proposto como um gatilho para FES [11], mas o nível de recrutamento muscular para o membro não afetado pode ser inferior ao necessário para aumentar a plasticidade no membro parético. Por essas razões, neste trabalho nos concentramos no desenvolvimento de um método melhorado para reconhecimento de gestos do membro contralateral baseado em EMG para o movimento de membros paréticos assistido por FES.

O reconhecimento de gestos baseado em EMG geralmente é um tópico de pesquisa relacionado ao controle de próteses para amputados trans radiais. De fato, melhorias nesta área são necessárias, uma vez que os estudos indicam que os amputados raramente usam mãos robóticas com regularidade [12], devido a problemas de usabilidade, como o número reduzido de graus de liberdade e a necessidade de reposicionamento e retreinamento diários. Desta forma, pesquisas utilizando superfícies [13] ou mecanismos invasivos [14] são comuns.

O uso da PCA na classificação de sinais de EMG multicanais é um procedimento comumente utilizado em trabalhos voltados para a reabilitação e controle de próteses e no desenvolvimento de sistemas de reconhecimento de padrões [15]. A redução dimensional pode ser aplicada tanto diretamente ao sinal de EMG quanto sobre características extraídas do sinal, sejam temporais ou em frequência [16].

## 1.2 DEFINIÇÃO DO PROBLEMA

Os setores de reabilitação fisioterapêutica e de tecnologias assistivas podem ser amplamente beneficiados com os avanços das tecnologias ubíquas. Pessoas que apresentam mobilidade limitada necessitam de interfaces inteligentes e imperceptíveis ao usuário. Pacientes em processo de recuperação de movimentos ou em adaptação a tecnologias de assistência ao movimento podem ter seus mais diversos sinais biométricos medidos em tempo real, processados e interpretados para enviar comandos para dispositivos ubíquos ao seu redor ou potencializados para o controle de próteses e dispositivos de apoio ao movimento, bem como para avaliação da eficiência de técnicas fisioterápicas.

Os métodos para reconhecimento de gesto de membro superior encontrados na literatura que apresentam taxa de acerto média superior a 80% necessitam de processos longos e repetitivos de inicialização. Já as técnicas que atingem mais de 90% de taxa de média de acerto apresentam falta de conveniência e naturalidade no uso dos dispositivos de reconhecimento, seja por serem muito grandes e pesados ou pela necessidade de estarem em ambientes muito específicos com variáveis controladas, tal como a luminosidade, cor de fundo, balizas de referência, os quais precisam ser muito bem configurados para um bom resultado.

Neste contexto, o problema abordado neste trabalho consiste na necessidade de métodos eficientes, rápidos e de fácil ou nenhuma configuração inicial, através de um dispositivo leve e que não necessite de um ambiente controlado para reconhecimento de gestos de membro superior contralateral baseado em EMG que possam ser utilizados em interfaces inteligentes para pessoas com pouca mobilidade bem como para a estimulação de membro parético em pacientes em reabilitação.

## **1.3 OBJETIVOS**

O objetivo geral deste trabalho consiste em estudar e avaliar formas de aquisição, processamento, extração e seleção de características de sinais de EMG utilizando tecnologias vestíveis a fim de classificar gestos de membros superiores. Pretende-se aplicar um sistema de aquisição de EMG multicanal econômico e fácil de usar, bem como avaliar seu desempenho de reconhecimento de gestos em um protocolo onde nenhum procedimento de inicialização seja necessário antes do uso.

O método inicialmente envolve o emprego de técnicas de aprendizagem de máquinas usando dados obtidos de um único usuário, para em seguida aplicar o algoritmo obtido para a classificação em tempo real de gestos de mão. Em vez de obter alto desempenho de classificação para usuários de prótese, a ideia é solicitar ao usuário o foco completo no gesto da mão estática, pois esse nível de concentração pode ajudar a acelerar a reabilitação.

Como último objetivo está o desenvolvimento de uma interface que possa ser integrada a dispositivos ubíquos de auxílio a pacientes que se encontram em recuperação de movimentos ou em adaptação a tecnologias de assistência ao movimento para que voltem a ter uma vida normal.

## **1.4 PRINCIPAIS CONTRIBUIÇÕES**

As principais contribuições desta dissertação são:

1. abordagem inovadora para clusterização, treinamento e classificação de dados de EMG do antebraço;
2. implementar uma aplicação em tempo real de reconhecimento de gesto de mão.

## **1.5 ORGANIZAÇÃO DO MANUSCRITO**

No capítulo 2 é feita uma revisão dos temas mais relevantes que formam a base técnica e teórica sobre para o desenvolvimento da dissertação. Em seguida, no capítulo 3, é apresentado todo o desenvolvimento do projeto, desde a extração dos dados, passando pelo tratamento dos sinais coletados e extração da informação de maior relevância através da técnica de Análise de Componentes Principais até a etapa de classificação resultando em uma pose previamente definida. Em seguida o leitor encontra os testes de desempenho do classificador, no capítulo 4. Por fim são apresentadas a conclusão da dissertação e trabalhos futuros sugeridos a partir do que foi desenvolvido, no capítulo 5.

# 2

## REVISÃO BIBLIOGRÁFICA

---

### 2.1 INTERAÇÃO HOMEM-MÁQUINA

Interação homem-máquina é a área que estuda interfaces entre o corpo humano e sistemas computacionais. Em muitos casos, por exemplo, utiliza-se o reconhecimento de padrões para a avaliação de sinais extraídos ou movimentos identificados e mapeá-lo a um comando para dispositivos de assistência. O reconhecimento de movimento humano pode considerar tanto o corpo inteiro quanto apenas um membro isoladamente. No primeiro caso avalia-se a posição de cada membro e a orientação das juntas, no segundo caso apenas a posição e orientação de um membro são avaliadas. Neste trabalho apenas poses do antebraço são avaliadas.

Uma forma de abordar este problema é utilizando a leitura de Eletromiografia (EMG) geradas a partir dos mais diversos movimentos do corpo, interpretá-las e mapear a comandos específico para um braço protético, robô de auxílio ou dispositivos ubíquos. Mesmo pacientes que perderam todo o braço podem usar braços protéticos mioelétricos que utilizam os sinais de EMG da musculatura residual para controlar os movimentos do braço protético após ser processado [17, 18].

De fato, apesar de não ser a forma natural de interação do homem com o ambiente, interfaces baseadas em sinais bioelétricos são as mais utilizadas para o controle ativo de órteses e próteses e apresentam eficiência semelhante a outros tipos de interfaces como as baseadas em força ou joysticks, que são tipos interfaces mais naturais de interação com o ambiente [17]. Algumas técnicas são comumente utilizadas para interfaces baseadas em EMG, tais como estimação do torque nas juntas musculares a partir dos sinais de EMG advindo das musculaturas que mais contribuem para a manutenção do movimento, reconhecimento de padrões dos sinais de EMG, ou mesmo técnicas cirúrgicas para reinervação dos músculos [19, 20].

A robótica vem sendo muito utilizada como *endpoint* da comunicação entre homem e máquina recebendo sinais de controle por meio de diferentes tipos de interfaces [21, 22, 23, 24], promovendo a restauração da funcionalidade de membros superiores ou inferiores [25] ou mesmo de várias partes do corpo simultaneamente por meio de exoesqueletos robóticos [26]. Estes robôs, além de desempenhar funções de dispositivo assistivo para amplificar as potencialidades do corpo humano, também podem oferecer apoio na reabilitação assistida por computador, detalhado na sessão 2.2.

Outra tecnologia de grande interesse são as interfaces cérebro-máquina (*brain-computer interface - BCI*). Neste caso utiliza-se o Eletroencefalograma (EEG), que é leitura da atividade cerebral espontânea captada através de eletrodos posicionados sobre o couro cabeludo, ou sinais provenientes de interfaces invasivas. A tradução destes sinais permite que pacientes possam interagir fisicamente com o ambiente. Tecnologias de BCI ainda são lentas e imprecisas em comparação com as demais apresentadas, mas muitas pesquisas avançam sobre esses aspectos [27].

## 2.2 REABILITAÇÃO ASSISTIDA POR COMPUTADOR

Pacientes que sofreram alguma lesão ou trauma que prejudica o movimento das mãos, ou que não podem se mover com agilidade devido a lesões que afetaram membros inferiores têm dificuldade em desempenhar certas tarefas que utilizem a mão ou que estão fora de seu alcance. Funções simples podem se tornar grandes obstáculos, tais como acender uma lâmpada, ligar um aparelho doméstico e pegar ou mover objetos. Por exemplo, no caso de indivíduos com amputação de membro superior, é preciso que o paciente possua interfaces que potencialize as capacidades que ele possui para que interaja com maior facilidade com sistemas computacionais que o auxiliem nessas tarefas. Avanços recentes em pesquisas vêm trazido bons resultados no uso de informações neurais para comunicação e controle, seja por métodos invasivos ou não, pode-se explorar a conexão com músculos, nervos ou cérebro para aumentar a funcionalidade destes pacientes [28].

O sistema nervoso central humano (SNC) possui grande adaptabilidade. Em casos de lesão sua característica de plasticidade permite a regeneração de regiões comprometidas alterando suas propriedades morfológicas e funcionais em resposta a variações do ambiente. O processo de reabilitação busca permitir que pacientes com alguma deficiência alcancem e mantenham suas capacidades funcionais físicas, sensoriais, intelectuais, psicológicas e sociais ao maior nível possível, provendo aos pacientes as ferramentas necessárias para atingir sua independência [29].

Tipicamente o tratamento por fisioterapia se inicia com a sessão de diagnóstico na qual as deficiências do paciente são avaliadas e uma primeira prescrição de exercício para melhorar as funções atingidas é passada ao paciente, incluindo exercícios a serem feitos em casa diariamente. O paciente então retorna à clínica a cada um ou duas semanas para reavaliação das suas condições e prescrição de novos exercícios ou outras decisões de tratamento. Quando o paciente realiza exercícios em casa o fisioterapeuta não consegue supervisionar adequadamente o desempenho do paciente, e faltam também dados que demonstrem que o paciente de fato seguiu a prescrição e de forma satisfatória. Isto dificulta ao profissional realizar decisões bem informadas e ajustes no tratamento. Para que possa tomar decisões conscientes o fisioterapeuta necessita de informações como frequência de execução dos exercícios, duração e repetição das sessões, velocidade média de execução, amplitude do movimento, sintomas ao realizar as atividades, tais como dor ou tontura, antes ou depois da execução, e quais erros o paciente cometeu [30].

Os métodos de terapias de reabilitação através da realização de tarefas específicas de forma repetitiva e o treinamento de movimentos por tempo prolongado são conhecidos e efetivos ao provocar os efeitos da neuroplasticidade das células nervosas necessários para a recuperação funcional da região lesionada. Entretanto, este trabalho é intensivo e prologado para o paciente e limita a habilidade do terapeuta de tratar vários pacientes. Também, com o envelhecimento das populações por todo o mundo, mais pessoas idosas, as quais requisitam mais atenção nos tratamentos médicos, estão demandando terapias de reabilitação. Todos esses fatores tornam o processo convencional de reabilitação um processo de custo elevado [31]. Segundo a Organização Mundial da Saúde o número de pessoas deficientes e que necessitam de serviços de reabilitação está continuamente crescendo e corresponde a aproximadamente 15% da população mundial [32].

Desta forma, este setor vem sendo foco de pesquisas e investimentos em soluções inovadoras em reabilitação assistida por computador (*Computer Aided Rehabilitation - CAR*) que possam aliviar o trabalho dos profissionais da área e melhorar a qualidade do tratamento para os pacientes, bem como para introduzir formas de avaliação dos exercícios feitos em casa pelo paciente. Inovações nas áreas computacionais e de comunicação tais como tecnologias ubíquas, pervasivas e distribuídas podem ser de grande ajuda em tratamentos de reabilitação, por meio de tratamentos complementares autônomos, incluindo terapia em casa.

Um *assistente de reabilitação virtual* poderia mediar uma conexão entre o paciente em casa e o terapeuta na clínica através de sensores de movimento vestíveis, tais como acelerômetros e giroscópios, ou câmera, realizando funções como: gravando as métricas dos exercícios realizados para avaliação de desempenho e assiduidade e enviar essas métricas para o fisioterapeuta em tempo real ou periodicamente; permitir que fisioterapeutas e pacientes vejam e quantifiquem o progresso com alta granularidade; gravar níveis de sintomas para auxiliar o profissional a calibrar a prescrição do exercício para maior efetividade; oferecer reconhecimento e feedback em tempo real de erros cometidos pelo paciente durante a execução dos exercícios [30].

Antes de desenvolver uma plataforma de assistência virtual é preciso se compreender alguns pontos de interesse sobre a ideia de projeto para verificar sua viabilidade: quais os dados do paciente são possíveis de ser extraídos; quais dados do paciente são de fato úteis para o a avaliação pelo fisioterapeuta; a precisão da medição dos dados é suficiente para a avaliação do profissional; de que maneira o paciente recebe a tecnologia vestível; de que forma o fisioterapeuta pode ajustar o dispositivo ou adaptar para novas necessidades sem precisar de uma equipe de engenharia; quais as preferencias do paciente quanto à resposta de desempenho pelo aparelho.

Outro aspecto de grande importância para o sucesso de processos de reabilitação é a motivação do paciente para dar seguimento ao tratamento. O tema é abordado pela literatura [33] não como essencial para a reabilitação, mas como uma das chaves para a eficiência do processo. As teorias mais utilizadas para motivação são a teoria da influência e a teoria da auto determinação. A primeira teoria pode mais facilmente ser implementada em projetos de *CAR* por meio mecanismos chamados de influencição da consciência, já a segunda depende de um trabalho individual com cada paciente para entender o que mais o motiva.

Seguindo a teoria da influência, alguns aspectos conceituais para a motivação são: competência, o paciente precisa se sentir capaz de realizar a tarefa proposta; conexão, o paciente precisa se sentir envolvido e pertencente ao processo; autonomia, o paciente se sente mais motivado quanto maior sua autonomia no processo. O mecanismo da influencição da consciência consiste em chamar a atenção do paciente para alguns pontos do processo que ele não percebe normalmente, mas que o motivam a seguir no exercício. Alguns exemplos são: reciprocidade, mostrar ao paciente sua evolução para chamar sua atenção para o que ele está ganhando no processo; escassez, inserir um mostrador chamando a atenção para a restrita quantidade de pessoas que têm acesso à plataforma utilizada pelo paciente; autoridade, mostrar um avatar do fisioterapeuta que indicou os exercícios. Por fim, o uso de *gameficação* é encorajado como fator de aumento da motivação.

Um caso prático de *CAR* é o *Centro de Reabilitação Ubíqua* [34], uma implementação de ambientes inteligentes e tecnologias ubíquas voltados para terapias de reabilitação baseado em redes sem fio onde se utiliza a tecnologia *Zigbee* para monitoramento e máquinas de apoio à reabilitação. Cada sensor possui uma interface com um ponto de conexão *Zigbee*, os quais se conectam com um servidor central que gerencia todos os aspectos da reabilitação, além de permitir aos especialistas determinar prescrições terapêuticas aos pacientes. Enquanto os pacientes executam as prescrições, diversos sensores monitoram, coletam e armazenam os dados relevantes da seção de terapia em uma base de dados. A partir desse ponto os profissionais da área avaliam as condições dos pacientes pela tendência dos seu dados e determinam novas prescrições. Assim o paciente é tratado de forma mais eficiente e com reduzido tempo total de reabilitação em comparação com métodos tradicionais.

## 2.3 RECONHECIMENTO DE GESTOS DE MEMBRO SUPERIOR

O reconhecimento de gestos de membros superiores, mais especificamente de mão, é um meio natural, inteligente e conveniente interação homem-máquina, sendo que reconhecimento de linguagem de sinais e controle baseado em comandos gestuais são duas das principais aplicações das tecnologias de reconhecimento de gestos [35]. A maioria dos trabalhos utiliza EMG de superfície em detrimento ao uso de sensores invasivos ou outro tipo de tecnologia, como através de imagens por exemplo. Reconhecimento de gestos de dedos [36] e de membros com amputação transradial [37] também foram abordados em trabalhos anteriores.

As técnicas mais utilizadas para a análise dos sinais de EMG e classificação dos gestos são baseadas em Modelos Ocultos de Markov (HMMs) e são empregados na identificação de alterações no sinal ao longo do tempo modelos de classificação offline dos dados [38]. Outras técnicas também são frequentemente utilizadas, como redes neurais artificiais [39, 37], análise das componentes principais [37] e máquina de vetor de suporte [40].

A maioria dos trabalhos utilizam a métrica de taxa média de acertos com análises sobre matrizes de confusão para avaliar o desempenho dos sistemas desenvolvidos. A grande maioria dos projetos atinge resultados maiores que 80% para a taxa média de acertos, em geral sob condições controladas. Os trabalhos que relatam taxas médias de acertos maiores que 90% sempre mostram perdas em outros aspectos, seja na falta de conveniência e naturalidade no uso de dispositivos muito grandes e pesados como luvas recobertas de sensores para captar movimentos da mão e de cada um dos dedos [35], ou na necessidade de ambientes muito específicos, que é o caso do uso de tecnologias de visão, onde a luminosidade e cor de fundo precisam ser muito bem configurados para um bom resultado[41]. Outros sistemas atingem altas taxas médias de acerto seja selecionando poucos gestos a reconhecer, podendo chegar a apenas dois gestos [39], ou realizando testes com poucos sujeitos [38].

## 2.4 AQUISIÇÃO DE SINAIS FISIOLÓGICOS

Em um ambiente de reabilitação assistida por computador onde existe interação homem-máquina a função geral dos sensores acoplados ao corpo do paciente é coletar sinais, muitas vezes analógicos, correspondentes a atividades fisiológicas humanas ou ações intencionais. O sinal analógico precisa ser então digitalizado por meio de um conversor analógico digital (A/D) para então ser enviado para uma complexa rede de comunicação que centraliza e analisa os dados em conjunto com informações de outros sensores acoplados ao corpo ou instalados no ambiente do paciente.

Um sensor acoplado ao corpo humano consiste basicamente de duas partes, a primeira é o transdutor que capta o sinal fisiológico e transmite um sinal elétrico, a segunda consiste na plataforma de comunicação com a rede de sensores para ser analisado.

Neste contexto uma grande variedade de modalidade de sensores foram desenvolvidos para obter informações relevantes ao funcionamento do corpo humano [42]. Os sensores vestíveis são aqueles diretamente acoplados ao corpo, seja sobre a pele, implantados, ou entre as faces do tecido das roupas e servem principalmente para extrair dados fisiológicos do paciente. Sensores de ambiente estão presentes no local onde o paciente se encontra, seja um ambulatório ou os cômodos da própria casa, incluindo ambientes de trânsito, sendo muito úteis para determinar comportamentos do indivíduo ou mesmo detectar quedas. Sensores de in-

teração com objetos únicos, para monitorar se um paciente toma o seu remédio corretamente, por exemplo, também são explorados.

No que se refere ao objeto da medição, diferentes tipos de sensores podem ser utilizados para aquisição de dados fisiológicos, alguns deles estão descritos abaixo [42] e sumarizados na tabela 2.1:

Sensor	Medida	Taxa de medição
Acelerômetro	Direção	Alta
Giroscópio	Orientação	Alta
Imagem/Vídeo	Atividade	Muito alta
Glocômetro	Açúcar no sangue	Alta
Pressão sanguínea	Oscilométrica	Baixa
CO <sub>2</sub>	Concentração de CO <sub>2</sub>	Muito baixa
ECG	Atividade cardíaca	Alta
EEG	Atividade cerebral	Alta
EMG	Atividade muscular	Muito alta
EOG	Movimento ocular	Alta
Oxímetro de pulso	Saturação de oxigênio no sangue	Baixa
GSR	Transpiração	Muito baixa
Térmico	Temperatura corporal	Muito baixa

Tabela 2.1: Tipo de sensores de sinais fisiológicos e seus respectivos níveis de taxas de medição.

- **Acelerômetro e giroscópio** utilizados para detectar a postura corporal (i.e. sentado, ajoelhado, deitado, andando, correndo, etc). Os acelerômetros utilizados para monitoramento de postura são sensores de 3-eixos, ou triaxiais, e são posicionados em posições bem definidas no corpo humano. Estes sensores também são úteis para medir vibrações ou acelerações devido à gravidade, importante para identificar quedas de idosos, por exemplo. Giroscópios são utilizados para estimar a orientação utilizando o princípio físico da conservação do momento angular. Giroscópios e acelerômetros costumam ser utilizados juntos para monitoramento de movimentos físicos.
- **Glocômetro** mede a quantidade de glicose circulando no sangue. Usualmente a glicose é medida furando a ponta de um dedo e colocando uma gota de sangue em contato com uma fita de teste que contém químicos reativos à glicose. O glocômetro é o medidor óptico que analisa a fita e apresenta um valor numérico para a concentração de glicose. Sensores não invasivos modernos utilizam radiação infravermelha.
- **Sensor de pressão sanguínea** mede por meio de técnicas oscilométricas não invasivas a pressão sanguínea sistólica e diastólica.
- **Sensor de CO<sub>2</sub>** mede ao nível de dióxido de carbono gasoso. É utilizado para monitores alterações de CO<sub>2</sub> durante a respiração humana.
- **Sensor de ECG** mede a atividade elétrica cardíaca. Suas principais utilidades são auxiliar no diagnóstico de doenças cardíacas e monitorar a reação de diferentes medicações para o coração. O sinal de ECG é obtido posicionando vários eletrodos em pontos específicos do peito e braço e medindo a diferença de potencial entre os eletrodos.

- **Sensor de EEG** mede a atividade elétrica do cérebro. A forma de monitoramento mais comum é não invasiva, um conjunto de sensores é posicionado sobre o couro cabeludo em diversos pontos, sendo comum o uso de toucas com sensores anexados. Outra abordagem de captura é posicionar sensores intracranianos, conhecida como eletrocorticografia (ECoG). Neste caso é preciso cirurgia para inserção dos sensores e, após o período de medições, para retirar os sensores. Os sinais de EEG são enviados para um amplificador para formar padrões gráficos.
- **Sensor de EMG** mede os sinais elétricos gerados pela atividade muscular em contração ou descanso. A medição pode ser invasiva, por meio de sensores acoplados diretamente à fibra muscular ao qual se deseja medir o sinal, ou não invasiva, utilizando eletrodos posicionados sobre a pele próximos aos músculos dos quais se quer medir a atividade. Uma vez que nervos conduzem impulsos elétricos que controlam a atividade muscular, sinais de EMG são utilizados para auxiliar no diagnóstico de enfermidades nervosas e musculares. Mais detalhes sobre sensores de EMG são dados a seguir, ainda nesta seção.
- **Oxímetro de pulso** mede a saturação de oxigênio no sangue de forma não invasiva. Um pequeno grampo é colocado sobre um dedo ou lóbulo da orelha. Um sinal de luz é emitido pelo sensor e passa pela pele e proporção de absorção de luz é medida. O resultado é expresso como um razão entre hemoglobinas oxigenadas e hemoglobinas totais no sangue arterial, pois a taxa de absorção de luz de hemoglobinas oxigenadas e não oxigenadas é diferente.
- **Sensores de temperatura e umidade** medem respectivamente a temperatura corporal e umidade ambiente. Estas variáveis são importantes para o tratamento de pacientes em geral e devem ser mantidas dentro de limites superiores e inferiores.

Uma vez que sensores estão em direto contato com o corpo humano ou mesmo implantados, eles precisam ter tamanho compatível com sua utilização e ser compatíveis com tecidos humanos

Neste trabalho faz-se um estudo que busca interpretar a pose do antebraço a partir da atividade muscular, bem como utilizar gestos do antebraço para enviar comandos para outros dispositivos conectados. Portanto, os tipos de sensores utilizados são sensores de EMG, que são detalhados abaixo.

### 2.4.1 Sensor de EMG

Sinais de eletromiografia são sinais elétricos resultantes da atividade muscular. Podem ser captados tanto de forma invasiva, por uma variedade de tipos de sensores que podem ser posicionados diretamente juntos à fibra muscular, como através de sensores posicionados sobre a pele. Sinais de EMG podem ser usados para diagnósticos clínicos, aplicações em biomédica e interfaces homem-máquina. Este último é conhecido como Eletromiografia de superfície (sEMG). Esta técnica tem a desvantagem de que o sinal captado sofre interferência dos músculos próximos em atividade simultânea aos músculos em observação. Mas por outro lado apresenta a vantagem de ser não invasivo e assim não ser necessário procedimento cirúrgico para sua inserção.

O fato do sistema nervoso controlar a atividade muscular, tanto contrações quanto relaxamento, e da atividade muscular depender das propriedades anatômicas e fisiológicas do músculo tornam a EMG um sinal complexo. Portanto, o estudo de técnicas e algoritmos eficientes de aquisição, decomposição, processamento e classificação dos sinais de EMG vêm ganhando importância neste ramo de pesquisa de forma a reduzir o ruído e aumentar a precisão dos métodos utilizados.

Ao obter e gravar sinais de sEMG dois pontos principais influenciam a fidelidade do sinal. O primeiro fator é a relação sinal-ruído, que é a razão entre a energia do sinal de EMG e a energia do ruído. O segundo fator é a distorção do sinal, que avalia alterações na contribuição relativa de cada componente de frequência do sinal de EMG.

Obter sinais do corpo humano através de eletrodos sobre a pele consiste na verdade em uma transdução de fenômenos eletroquímicos ocorrendo sob a pele. Desta forma, para efeitos de análises sinal-ruído, pode-se conceituar sinal como sendo o efeito percebido pelos eletrodos dos fenômenos aos quais se tem interesse. Ruído seria tudo aquilo que o sensor capta que não é o foco do experimento e que obscurece o sinal. Portanto, o que é considerado sinal em determinado experimento pode ser tratado como ruído em outro teste, e vice-versa.

No caso deste estudo em que o foco é a aquisição de atividade neural periférica, sinais são os potenciais elétricos produzidos por potenciais de ação caminhando pelas fibras musculares do braço atenuados pelas camadas de pele e gordura e pelos. Qualquer artefato, interferência causada por atividade em músculos vizinhos ou equipamentos elétricos são tratados como ruído.

Uma vez que sinais de sEMG são da ordem de 1uV a 100uV [1], a resposta do sensor deve ser amplificada para que possa ser analisada. Desta forma, torna-se muito importante o esforço para a eliminação ou atenuação de ruídos que possam ser amplificados e interpretados como sinal.

A qualidade do sinal adquirido pode ser medida tanto qualitativamente, por meio da coerência entre o sinal e o movimento muscular ao qual se espere que o sinal esteja mais intimamente relacionado, sendo que quanto maior for a seletividade da fibra nervosa maior será a coerência e maior a qualidade, como quantitativamente pela relação sinal ruído. Sinais crus coletados sobre a pele, que é o caso deste trabalho, se caracterizam por conter muito ruído devido à baixa seletividade pela distância entre o sensor e as fibras musculares e as diversas camadas de tecidos entre estes.

## 2.5 MYO ARMBAND

O dispositivo Myo Armband, do fabricante Thalmic Labs, consiste em um bracelete que deve ser posicionado no antebraço próximo ao cotovelo contendo sensores de EMG e sensores inerciais. O Myo deve ser vestido sempre com a entrada USB voltada para a mão.



Figura 2.1: Bracelete myo armband utilizado neste trabalho para medição de sinais de EMG do antebraço por 8 canais.

Suas principais especificações e funções são listadas abaixo.

- 8 Sensores proprietários de EMG de aço inoxidável de qualidade médica e alta sensibilidade;
- IMU de 9 graus de liberdade, contendo giroscópio triaxial, acelerômetro triaxial, magnetômetro triaxial;
- 2 LEDs indicadores de status;
- Bateria embarcada recarregável de íon-lítio;
- Entrada micro USB para carregar a bateria;
- 10 presilhas para ajuste de tamanho, que varia de uma circunferência de antebraço de 19 cm a 34 cm;
- Processador ARM Cortex M4;
- Interface háptica vibratória para feedback ao usuário, podendo ser ajustada em três níveis: curto (23,5 ms), médio (45,6 ms) e longo (100,5 ms);
- Reconhece 5 gestos de mão por padrão: toque duplo (*double-tap*), punho fechado (*fist*), dedos abertos (*fingers spread*), mão para dentro (*wave in*), mão para fora (*wave out*), conforme Figura 2.2;
- Orientação em 3 eixos resultado de cálculos realizados pelo próprio processador embarcado no dispositivo: arfagem (*pitch*), rolagem (*roll*), guinada (*yaw*);
- Conexão Bluetooth 4.0 de baixo consumo para MAC e Windows PC com conector USB;
- Função de travamento. Quando está travado o dispositivo deixa de reconhecer gestos;
- Peso de 93 gramas;

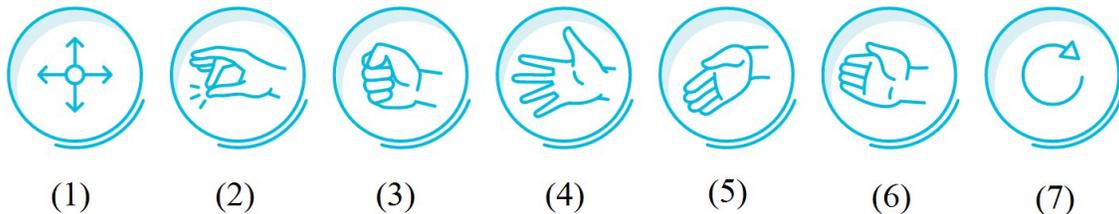


Figura 2.2: Funcionalidades nativas do Myo armband. (1) leitura de aceleração linear. (2) toque duplo (*double-tap*). (3) punho fechado (*fist*). (4) dedos abertos (*fingers spread*). (5) mão para dentro (*wave in*). (6) mão para fora (*wave out*). (7) leitura de velocidade angular.

O fabricante do Myo disponibiliza uma SDK para o desenvolvedores com objetivo de obter os dados capturados pelo Myo e informações sobre seu status, como bateria e se está bloqueado ou não, bem como para programação utilizando todas as capacidades do Myo que oferece três tipos de informação: espacial (captados pela IMU), gestual, e dados de EMG - captados pelos seus sensores superficiais. Os dados espaciais são tanto de orientação, fornecendo informação sobre para onde o dispositivo está apontando, quanto de aceleração do dispositivo no espaço. O Myo também oferece uma interface háptica, permitido ao desenvolvedor fornecer feedbacks ao usuário por meio de vibrações com períodos mais ou menos longos.

As principais desvantagens de se trabalhar com o Myo são a grande quantidade de ruído, uma vez que os sensores são postos sobre a pele (skin-mounted), dificultando a captação do sinal de ativação muscular, que precisa por camadas de pele e gordura; baixa seletividade, pois o sensor é colocado sobre vários músculos simultaneamente. Desta forma as características do sinal variam muito de um experimento para o outro dependendo de fatores como diferentes espessuras do braço, camadas mais ou menos grossas de gordura, músculos mais fortalecidos ou não, grandes quantidades de cabelo na pele do braço. Todos estes fatores dificultam a padronização de limites de reconhecimento.

Outro fator de grande dificuldade é variabilidade na forma com que cada pessoa executa seus movimentos. Cada pessoa utiliza estratégias próprias para executar determinada trajetória ou movimento de mão, recrutando desta forma músculos diferentes com esforços variados, resultando em padrões irregulares de magnitude de sinal.

## **2.6 EXTRAÇÃO DE CARACTERÍSTICAS**

A extração e seleção de características de um sinal é utilizada como uma fase prévia ao reconhecimento de padrões, a fim de aumentar a precisão e reduzir a complexidade computacional. Extrair características de um sinal consiste em aplicar uma transformação ao conjunto inicial de medidas para criar um conjunto de características derivadas destes dados. A seleção de características busca encontrar um subconjunto das características transformadas de forma a otimizar o desempenho do classificador. Portanto, a seleção de características se caracteriza como um problema de busca, onde o objetivo é encontrar o melhor subconjunto baseado em alguma métrica de forma a reduzir o número de características de entrada para o classificador, diminuindo a complexidade deste e aumentando a velocidade dos testes do classificador. Outros objetivos da seleção de características são reduzir o impacto de características com muito ruído, bem como de características redundantes ou correlatas, que não agregam informação e aumentam a complexidade do classificador.

No caso deste trabalho, as características podem ser extraídas a partir dos sinais de EMG gerados por vários canais, esta seria a etapa de extração de características, que gera as características para análise. A fase de seleção de características é o estágio de redução dimensional, que diminui o tamanho do conjunto de características. Neste trabalho, o processo de extração de características consiste no cálculo de algumas características básicas e de meta características. A seleção de características é realizada pela análise por PCA, explicada adiante. Em seguida, a etapa de classificação utiliza técnicas de clusterização por k-means e seleção de saída por MBT, sendo que os testes do MBT são feitos utilizando separação por SVM ambos também descritos com mais detalhes a frente.

### **2.6.1 Características do EMG**

Para o cálculo das características básicas de EMG o sinal é dividido em janelas de tempo. Cada característica é calculada dentro de cada janela, gerando uma matriz de valores como resultado. Tanto características no domínio do tempo quanto no domínio da frequência podem ser avaliadas. Alguns trabalhos se dedicam ao estudo e avaliação destas características em variadas circunstâncias, os quais descrevem as equações com detalhes. As características utilizadas neste trabalho são comumente utilizadas no tratamento de sinais de EMG [43], e foram selecionadas apenas nove características que não demandam grande custo computacional,

de forma a evitar que o sistema se torne lento devido a grande quantidade de cálculo de características . As características utilizadas estão descritas a seguir, onde  $W$  é a quantidade de itens da janela e  $EMG(t)$  é o valor do EMG para o tempo  $t$  dentro da respectiva janela. O operador  $E$  se refere à expectativa. A média do conjunto de dados é  $\mu$ , enquanto o desvio padrão é  $\sigma$ .

- Valor quadrático médio (RMS)

$$RMS(w) = \sqrt{\frac{1}{W} \sum_{i=1}^W EMG(t)^2} \quad (2.1)$$

- Variância

$$VAR(w) = \frac{1}{W} \sum_{i=1}^W EMG(t)^2 \quad (2.2)$$

- Integral do EMG

$$INT(w) = \sum_{i=1}^W |EMG(t)| \quad (2.3)$$

- Skewness

$$SKW(w) = E\left[\left(\frac{EMG - \mu}{\sigma}\right)^3\right] \quad (2.4)$$

- Kurtosis

$$INT(w) = \frac{E[(EMG(t) - \mu)^4]}{(E[(EMG(t) - \mu)^2])^2} \quad (2.5)$$

- Waveform change

$$WC(w) = \sum_{i=1}^{W-1} |EMG(t+1) - EMG(t)| \quad (2.6)$$

- Zero crossing: esta características é a medida de quantas vezes o sinal de EMG varia de positivo para negativo ou de negativo para positivo considerando um limiar para evitar que flutuações próximas do valor zero sejam contabilizadas. Esta característica é calculada com o valor obtido do EMG antes do pré-processamento, pois um dos processos desta etapa é obter o valor absoluto do sinal.
- Active: esta característica é binária e determina se um canal está ativado ou não. Se o valor absoluto do sinal esta acima de um limiar pré definido o resultado é um 1, caso contrário o resultado é 0.
- Envolvória: o valor absoluto do sinal passa por um filtro passa-baixa de 20Hz, formando esta característica. O nome envoltória se deve ao fato de que o resultado se assemelha um contorno sobre o sinal.

## 2.6.2 Técnicas supervisionadas e não-supervisionadas

Processos de seleção de características podem ser divididos em duas classes: supervisionadas ou não-supervisionadas. A maioria dos algoritmos dessa área se concentra na classe de supervisionadas. Neste caso, a ideia é mapear as variáveis de entrada ( $X$ ) às variáveis de saída ( $Y$ ) por meio de uma função de mapeamento  $Y = f(X)$ .

Ao ajustar a função de mapeamento de forma a contemplar várias situações de entradas e saídas, ao inserir novas variáveis de entrada no sistema será possível prever quais as variáveis de saída aplicando a função de

mapeamento às entradas. Técnicas supervisionadas requerem uma fase de treinamento supervisionado, por isto a nomenclatura, na qual conjuntos de entradas são apresentadas iterativamente e o algoritmo responde com as saídas enquanto o método de treinamento corrige o algoritmo de forma a ajustar a função de mapeamento. O treinamento encerra quando nível de acertos determinado é atingido.

Problemas de aprendizagem supervisionada são chamados de classificação quando as saídas são categorias e regressão quando as saídas são valores mensuráveis. Alguns algoritmos que implementam esta técnica são: regressão linear; *random forest*; máquina de vetor de suporte.

Algoritmos de aprendizagem não-supervisionados recebem como parâmetro variáveis de entrada ( $X$ ), mas sem variáveis de saída correspondente. A ideia é criar um modelo do sistema, aprendendo sobre seu comportamento, de forma que não existe uma saída correta para um conjunto de entrada. Problemas dessa natureza são divididos em agrupamento (*clustering*), que separa as entradas em grupos que não forma previamente definidos conforme suas características sejam semelhantes; e associação, técnica que busca descobrir regras que descreva o sistema baseado nas variáveis de entrada.

Caso apenas uma porção do conjunto de variáveis de entrada possua saída correspondente, o problema é de aprendizagem semi supervisionada [44].

## 2.7 ANÁLISE DE COMPONENTES PRINCIPAIS

Cada movimento do corpo humano, por mais simples que seja, recruta diversas fibras musculares da região movimentada. Um conjunto de sensores posicionados sobre a pele captando sinais de várias regiões próximas ao movimento registram grande quantidade de dados em várias dimensões. Esse grande conjunto de dados pode passar por processos de análise de dados para e ser transformado em um conjunto de dimensão menor, é o que se chama redução dimensional de dados. O objetivo é reduzir os dados aos seus componentes básicos, retirando toda informação redundante e desnecessária. Esse processo possibilita que a detecção de padrões seja feita mais claramente.

Uma técnica para redução dimensional é a Análise de Componentes Principais. Esta técnica tem como parâmetros de entrada conjuntos de dados em várias dimensões, a ideia básica é extrair as dimensões com maior variância, ou seja, com maior relevância para a avaliação dos dados. As componentes principais são o resultado da PCA, e são uma combinação linear das variáveis originais, bem como são não correlacionados. Trata-se de uma técnica estatística de redução dimensional não-supervisionada.

PCA é um algoritmo estatístico de redução dimensional de dados. É utilizado para acelerar significativamente algoritmos de aprendizagem não-supervisionados. Tem uso em diversos campos da engenharia como reconhecimento de faces e compressão de imagens, especialmente quando se deseja encontrar padrões em conjuntos de dados de grandes dimensões. O processo de PCA busca encontrar uma base ortogonal que maximize a variância dos dados, e pode ser sumarizado em alguns passos:

1. **Pré processamento** - tratamento dos dados antes da análise;
2. **Remover as médias** - deixar todas as dimensões com média zero;
3. **Normalizar dados** - os dados de cada dimensão são divididos pelo desvio padrão;
4. **Covariância** - calcular a matriz de covariância;

5. **Autovetores** - calcular os autovalores e autovetores da matriz de covariância;
6. **Whitening** - os autovetores são normalizados utilizando a técnica *whitening*, que consiste em dividir cada autovetor pela raiz quadrada do autovalor correspondente, de forma a facilitar a comparação entre eles;
7. **Componentes principais** - as componentes principais são os autovetores, ou seja, os vetores que definem as novas dimensões dos dados.
8. **Rank** - escolher os autovetores de maior relevância, quanto maior o autovalor associado a ele melhor o seu rank;
9. **Projeção** - projetar os dados sobre as componentes escolhidas;
10. **Clusterização** - esta etapa já não faz parte do processo de PCA. O agrupamento dos dados de entrada é feito baseado nas novas dimensões.

A técnica de PCA é muito útil para lidar com grande quantidade de variáveis. Para fins de compreensão do processo, considere um conjunto de dados de entrada ( $x$ ) de dimensão  $n = 2$  de modo que  $x_i \in \mathbb{R}^2$  para que seja possível a visualização gráfica do processo. O objetivo é reduzir a dimensão dos dados de 2 para 1.

<b>x</b>	2,5	0,5	2,2	1,9	3,1	2,3	2,0	1,0	1,5	1,1
<b>y</b>	2,4	0,7	2,9	2,2	3,0	2,7	1,6	1,1	1,6	0,9

Tabela 2.2: Dados originais em duas dimensões antes do procedimento de exemplo de PCA.

Inicialmente é feito um pré-processamento dos dados. Nesta etapa, para cada dimensão, ou *característica*, os dados devem ter a mesma média (zero) e a mesma variância. Os dados originais e pré-processados são mostrados na Figura 2.3.

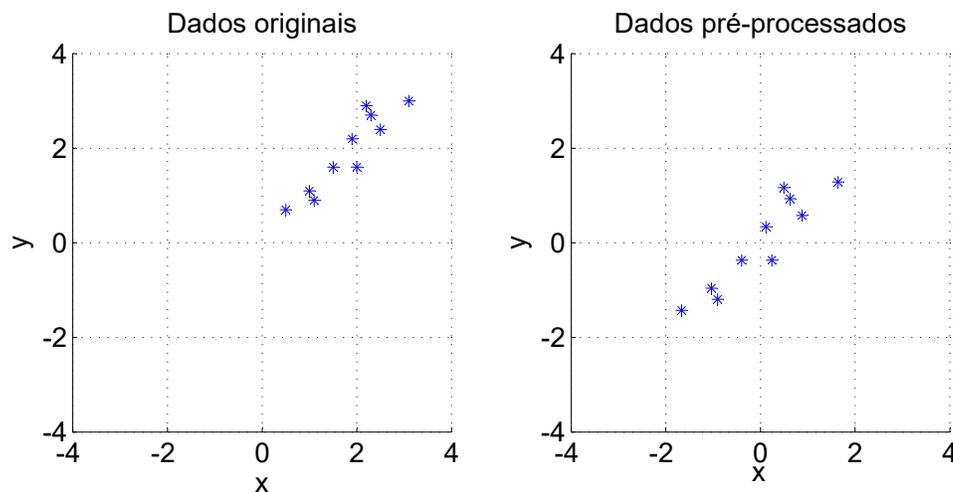


Figura 2.3: Dados originais e pré-processados antes do procedimento de exemplo de PCA.

Em seguida é calculada a matriz de covariância dos dados normalizados. Uma vez que os dados estão dispostos em duas dimensões, a matriz de covariância será de dimensão  $2 \times 2$ ,  $\mathbf{C} = \begin{bmatrix} 1,0000 & 0,92590 \\ 0,92591 & 1,0000 \end{bmatrix}$ .

Os autovetores  $\mathbf{V} = \begin{bmatrix} -0.7071 & 0.7071 \\ 0.7071 & 0.7071 \end{bmatrix}$  e seus respectivos autovalores  $\boldsymbol{\lambda} = \begin{bmatrix} 0.0741 \\ 1.9259 \end{bmatrix}$  são calculados a partir da matriz de covariância.

Portanto, as componentes principais deste conjunto de dados estão na direção dos vetores  $\mathbf{v1} = (-0.7071x + 0.7071y)$  e  $\mathbf{v2} = (0.7071x + 0.7071y)$ . Plotando os vetores das componentes principais juntamente com os dados, ver Figura 2.4, é possível perceber visualmente que os dados realmente variam na orientação da componente principal de maior rank.

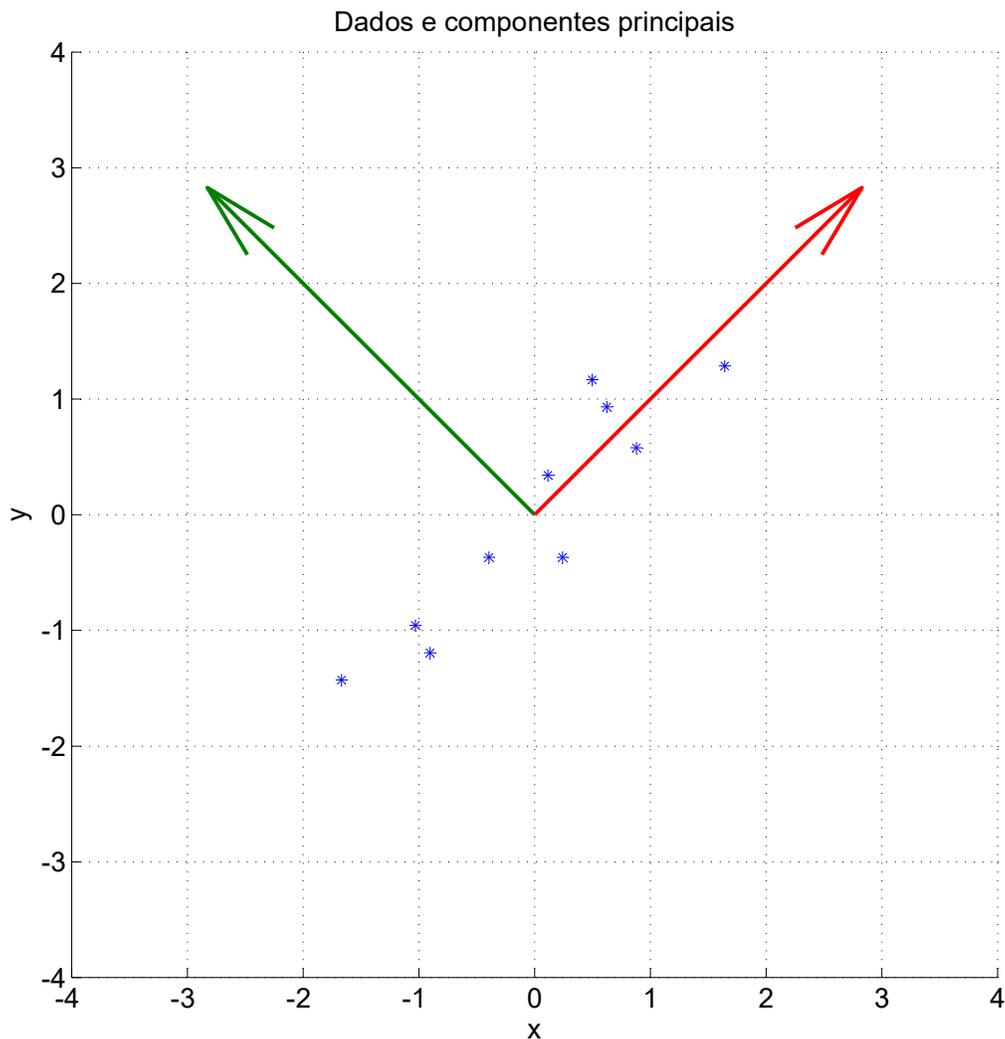


Figura 2.4: Dados e componentes principais após o procedimento de exemplo de PCA.

Antes do rankeamento os autovetores passam por uma normalização conhecida como *whitening*, cujo objetivo é tornar os dados menos redundante e com a mesma variância. Em termos práticos normalização

por whitening consiste em dividir cada autovetor pela raiz quadrada do autovalor correspondente, ou seja  $\mathbf{V}_{\text{white},i} = \frac{V_i}{\sqrt{\lambda}}$ .

Corroborando a indução visual pode-se observar que o componente principal de maior rank é o segundo vetor  $V_2 = (0.7071x + 0.7071y)$ , que tem autovalor igual a 1,9259, enquanto o autovalor de  $V_1$  é igual 0,0741. Portanto, uma vez que precisamos reduzir os dados para apenas uma dimensão, apenas a componente de maior rank será utilizada. Agora os dados são projetados sobre a componente selecionada, ignorando qualquer variação em outra dimensão, ou seja, a representação será unidimensional, como mostrado na Figura 2.5.

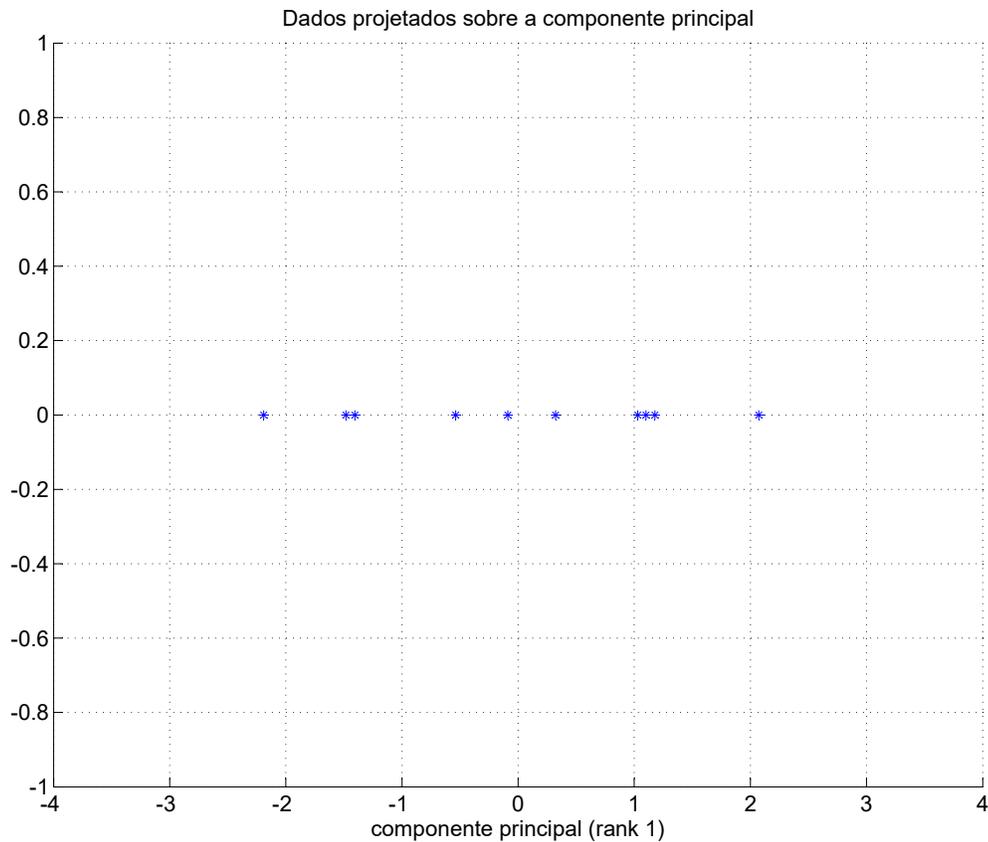


Figura 2.5: Dados projetados sobre a componente principal de maior rank obtidos através da técnica de PCA de exemplo.

Neste ponto os dados de entrada estão representados apenas em uma dimensão, que é a de maior relevância por conter a maior variância dos dados. A sequência natural é agrupar as entradas baseado na informação dos dados projetados, este processo é detalhado na seção 2.8.

## 2.8 CLASSIFICAÇÃO

Classificadores, ou seletores de saídas, são ferramentas matemáticas utilizadas para agrupar conjuntos de dados conforme suas características similares. O desempenho de um classificador está intensamente ligada com o tipo dos parâmetros de entrada, dos padrões de saída e do tipo do classificador.

Um problema de classificação pode ser dividido em várias etapas com menor complexidade cada uma. Tal granularidade pode chegar até a divisão em sequências de decisões binárias. As decisões binárias podem tanto ser uma decisão de “um para muito”s ou de “um para um”, bem como variantes destes. No primeiro caso uma saída é considerada em relação várias outras, e a decisão consiste em determinar o resultado como a saída isolada ou alguma das demais. No segundo caso, “um para um”, duas saídas isoladas são consideradas, a resposta deve ser ou uma ou outra saída.

### 2.8.1 Classificação do movimento humano

No caso da classificação do movimento humano, é possível diferenciar movimentos utilizando apenas parte dos dados disponíveis de uma série de dados no tempo, i.e. pode-se identificar características do início e do fim do movimento sem calcular toda a trajetória do movimento. É preciso considerar também que cada característica terá uma evolução no tempo, e que essas características subsequentes no tempo provavelmente possuem correlação umas com as outras uma vez que pessoas se movem a uma velocidade finita e o corpo possui restrições cinemáticas e dinâmicas.

Neste caso, o objetivo da seleção de características é escolher momentos específicos de cada característica no tempo de forma a reduzir a necessidade de memória do classificador e o tempo de resposta, mas mantendo a precisão próxima a se estivesse utilizando todos os dados disponíveis. A técnica de clusterização por *k-means* é utilizada para agrupar e analisar os resultados da fase de extração de características e selecionar as características relevantes para cada gesto ou movimento. Então, as características selecionadas são utilizadas em conjunto com um classificador do tipo MBT para gerar uma árvore de decisão de gestos e movimentos da mão.

### 2.8.2 K-means

Em mineração de dados um problema comum é encontrar grupos, ou *clusters*, que minimize a variância interna de cada *cluster* em um conjunto de pontos. Entretanto, a solução ótima para este problema é de complexidade computacional de ordem NP-complexo [45], i.e. são solucionáveis em tempo polinomial por um algoritmo não determinístico. Todavia, existe uma solução heurística que oferece uma solução aproximada para este problema com resultados e velocidade razoáveis. Tal solução pode incorrer em duas situações extremas. A primeira é que no pior caso o problema requer tempo de execução super-polinomial, a segunda situação é quando a solução atinge um mínimo local muito distante da solução ótima, gerando resultados muito ruins. Estas situações extremas podem ser amenizadas com uma inicialização apropriada, como será falado a frente. Outro problema deste método é a escolha da quantidade *k* de clusters.

O agrupamento pelo algoritmo *k-means*, também conhecido como algoritmo de Lloyd [46], se caracteriza por particionar os dados de entrada em *k* grupos, sendo que cada item pertence ao grupo cuja média, ou centróide, é a mais próxima de si, de forma a minimizar as distâncias ao quadrado em cada dimensão entre os

membro de um cluster. De modo geral, o objetivo é minimizar a função de custo  $\sum_{i=1}^k \sum_{x,y \in C_i} d(x,y)^2$ .

A heurística de Lloyd para clusterização é amplamente utilizada para clusterização, quantização vetorial, aprendizado semi supervisionado, e possui comprovações e melhorias posteriores [47].

A distância entre os pontos usada no algoritmo *k-means* utilizada para a minimização pode ser calculada por várias medidas. A medida mais comum é a distância Euclideana ao quadrado entre o ponto e o centróide. Outros exemplos de métodos são: a soma das diferenças absolutas em cada dimensão; um menos o cosseno do ângulo entre o ponto e centróide, ambos tratados como vetores.

O processo proposto pelo algoritmo *k-means* é iterativo. O primeiro passo é escolher a quantidade  $k$  de centróides, ou clusters, que o algoritmos deverá agrupar os dados. Em seguida é feita a inicialização, a qual pode ocorrer de diversas maneiras, seja selecionando  $k$  itens aleatoriamente entre os dados de entrada como os centróides iniciais, ou selecionando os  $k$  primeiros itens da lista de dados de entrada, ou por seleção manual da posição inicial dos centróides, ou mesmo utilizando algoritmos mais complexos como *k-mean++*, que propõe as vantagens de uma inicialização mais cuidadosa [48]. O algoritmo aumenta a velocidade de convergência do algoritmo de Lloyd, bem como a qualidade do resultado, o qual depende muito da inicialização, pois pode convergir para mínimos locais da função a ser minimizada??, como explicado anteriormente.

O *k-mean++* segue os seguintes passos: (1) inicia escolhendo aleatoriamente uma das observações considerando todos os pontos com distribuição de probabilidade uniforme, ou seja um ponto dos dados de entrada, o qual será o primeiro centróide; (2) então, deve-se calcular a distância entre cada observação e o centróide mais próximo que já foi selecionado; (3) em seguida, escolha aleatoriamente o próximo centróide dentre os pontos que não sejam o primeiro centróide, mas desta vez a distribuição de probabilidade é diferente, cada ponto tem maior peso quanto maior for a sua distância para os centróides já existentes; por fim, de forma iterativa os passos 2 e 3 devem ser seguidos até que  $k$  centróides sejam selecionados. Uma vez que os centróides iniciais, ou *seeds*, estão definidos pode-se iniciar o algoritmo *k-means*.

Após feita a inicialização que resulta nos centróides iniciais, começam as iterações. Cada iteração é composta por três fases. Na primeira fase calcula-se a distância entre cada observação e cada centróide, então cada ponto é atribuído ao cluster cujo centróide está mais próximo, todos são movidos ao mesmo tempo. Dependendo do tamanho do conjunto de dados de entrada o mínimo global pode ser encontrado nesta fase, mas mais frequentemente esta fase é apenas um preparativo para a segundo. Na segunda fase calcula-se a distância entre cada observação e cada centróide, então cada ponto, um por vez, é atribuído a um novo cluster caso esta alteração resulte em uma redução na soma das distâncias. Em seguida, os centróides dos clusters são calculados novamente após cada nova atribuição. A segunda fase resulta em um mínimo local. O mínimo global da função de minimização é encontrado por meio da replicação exaustiva do processo trocando os centróides iniciais.

Processos de redução dimensional não supervisionado, PCA por exemplo, estão intimamente relacionados à aprendizagem não supervisionada utilizando o algoritmo *k-means*, pois os subespaços divididos pelos centróides dos  $k$  clusters em um processo de aprendizagem por clusterização são dados pela expansão espectral da matriz de covariância dos dados avaliados truncados no termo  $k - 1$  [2]. Intuitivamente pode-se perceber que para um agrupamento em 2 clusters, a linha que liga os dois centróides é a direção da melhor projeção em uma dimensão dos dados, ou seja, a direção primeira componente da PCA.

Voltando ao exemplo da sessão 2.6, aplicando o método *k-means* com dois centróides obtém se o resultado da Figura 2.6.

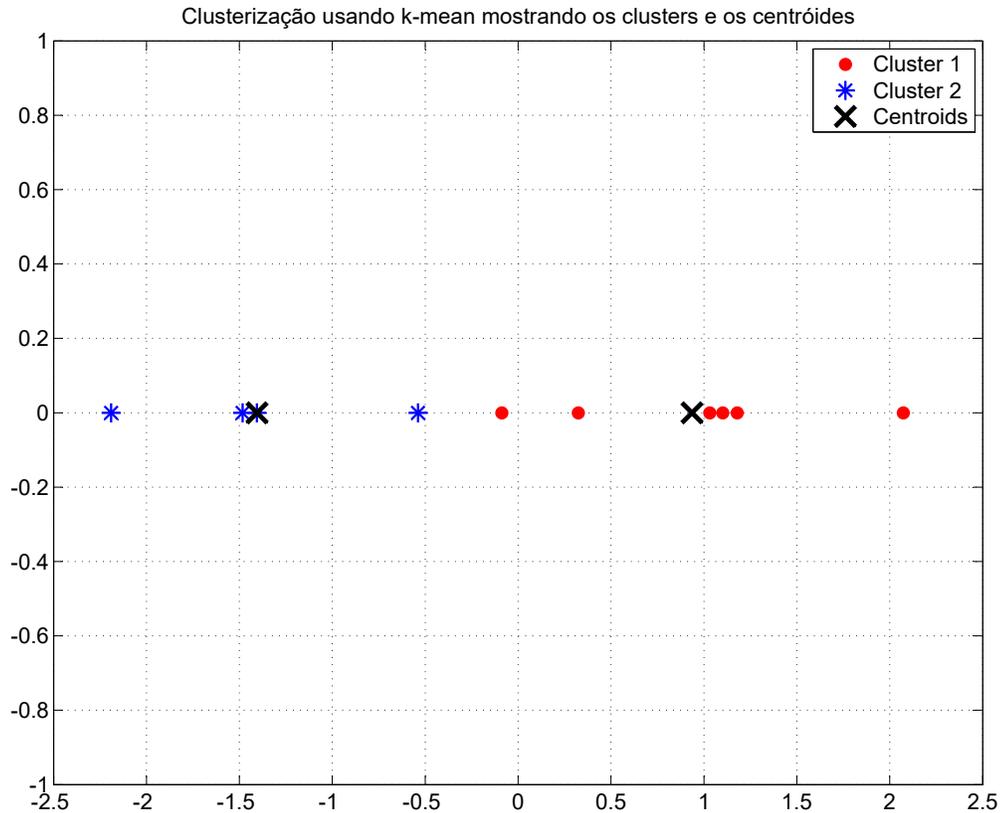


Figura 2.6: Dados agrupados em dois cluster através do método k-mean mostrando os clusters e os centróides.

### 2.8.3 Classificadores binários estendidos para multi classe

Classificadores binários podem ser estendidos para problemas multi classe de diversas maneiras, uma delas é por meio de classificadores hierárquicos. Estes classificadores se caracterizam por reduzir progressivamente o conjunto de classes a cada teste até que reste apenas uma classe, ou nó. Vários métodos já foram desenvolvidos neste sentido, uma abordagem proposta é criar árvores binárias para classificação por SVM utilizando *Self-Organizing Maps* (SOM) para criar grupos [49].

Neste tipo de classificadores hierárquicos multi classe estendido de binário do tipo “um contra resto”, uma árvore binária desbalanceada de vários níveis é criada. Em cada nó é realizado um teste, dependendo do resultado a entrada recebe uma classe ou passa para o próximo nível de teste, como mostrado na Figura 2.7. O passo mais importante são a seleção e configuração dos nós de teste, enquanto a ordem destes testes importa pouco [50].

Em relação ao teste nos nós, o uso da abordagem “um contra resto” se mostra mais vantagem que “um contra um”, visto que a quantidade de classificadores a ser treinado é menor. Além disso, diferentes classes podem ser melhor separadas utilizando diferentes conjuntos de características. A subdivisão do problema permite o uso de características específicas para cada classe.

De fato, classificadores no formato de árvore binária de decisão são necessariamente hierárquicos, uma vez que a cada decisão tomada em níveis menores restam menos entradas para as próximas subclassificações. O uso de estruturas em árvore é intuitivamente uma boa escolha pois ela não exige que todos os classificadores

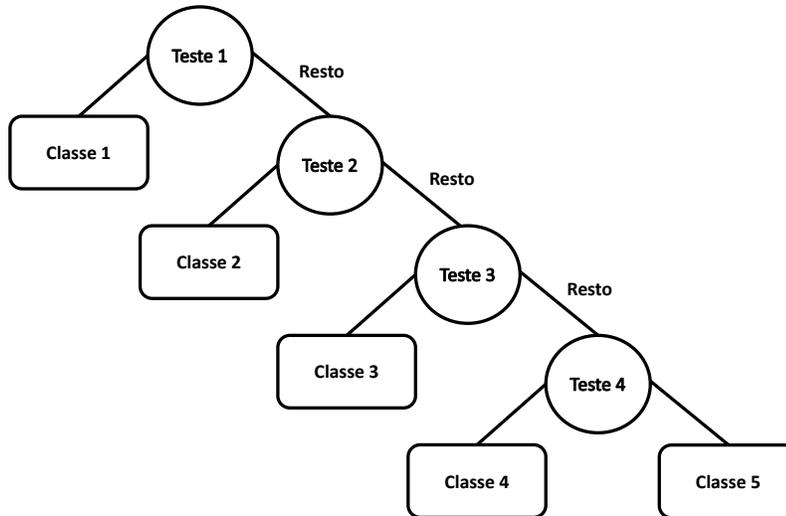


Figura 2.7: Árvore binária formada pelo classificador do tipo “um contra resto” para a separação de cinco classes realizada por no máximo quatro testes.

treinados sejam testados para cada entrada, reduzindo o tempo de classificação.

### 2.8.4 Multi-Modal Binary Tree (MBT)

A utilização de árvores binárias para classificação multimodal, ou multi classe, onde cada nó folha representa uma classe de saída, requer o treinamento de  $(C - 1)$  classificadores, onde  $C$  é quantidade de classes de saída. A maior vantagem deste tipo de classificador não está no tempo de treinamento, mas no tempo de teste, o que é de suma importância para desempenho *online*. O MBT permite que conjuntos de dados não lineares e multi classes possam ser separados utilizando um conjunto de classificadores simples, como classificadores do tipo SVM lineares.

O uso de classificadores MBT é intuitivo para reconhecimento de gestos e movimentos de mão, pois movimentos humanos são coordenados por um estrutura hierárquica natural. Por outro lado, cada pessoa utiliza estratégias diferentes para realizar um movimento. Esta variedade de estratégias poderia gerar diversos clusters para a mesma classe de movimentos, ou seja, um conjunto multi modal de dados.

### 2.8.5 Máquina de Vetor de Suporte (SVM)

SVM é uma técnica utilizada para a separação de duas classes. O processo de classificação busca encontrar o melhor hiperplano que separa todos os pontos de uma classe da outra. O melhor hiperplano é aquele com a maior margem entre as duas classes. Margem é o espaço que separa a borda de uma das classes ao hiperplano, no qual não há nenhum ponto no interior. Os vetores de suporte são pontos que se encontram exatamente nas bordas das classes, e portanto estão mais próximos do hiperplano. A Figura 2.8 exemplifica duas classes sendo separadas por um hiperplano, bem como os vetores de suporte e a margem.

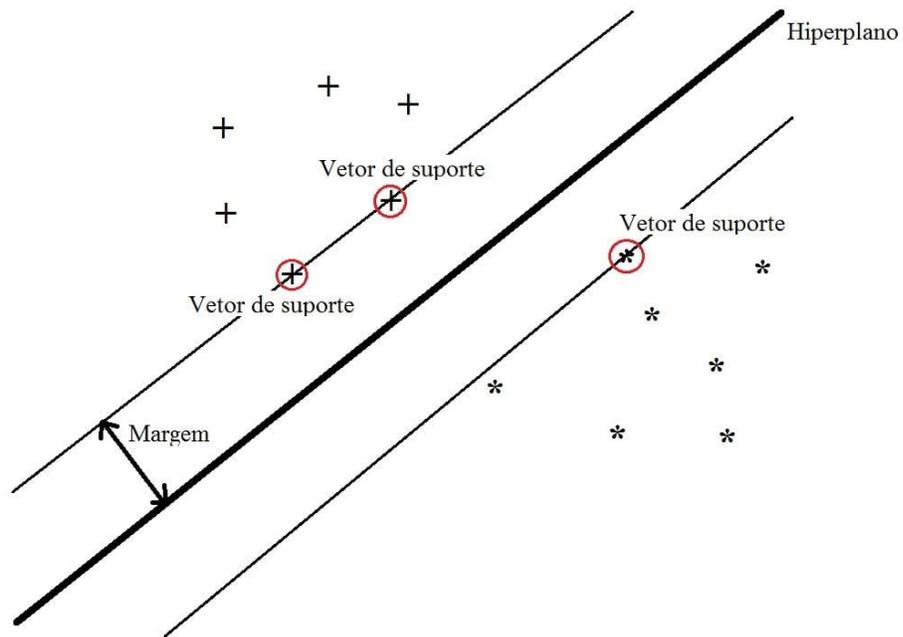


Figura 2.8: SVM linear.

SVMs devem ser treinadas antes de utilizadas, pois é um modelo de aprendizado supervisionado, e então usa a SVM treinada para classificar, ou prever, a classe de novos dados de entrada. Dependendo da distribuição das classes é possível utilizar vários tipos de funções kernel em uma SVM, as quais podem ter seus parâmetros calibrados para melhor desempenho. Alguns exemplos de kernel são: linear, quadrático, polinomial, gaussiano, percéptrons multicamadas, ou mesmo funções personalizadas.

# 3

## RECONHECIMENTO DE GESTOS

---

Neste capítulo são apresentadas as etapas do desenvolvimento do projeto e suas nuances com o objetivo primeiro de demonstrar como se chegou aos resultados que são apresentados mais a frente e também permitir que todo o processo seja replicado por quem se interesse em fazê-lo. Em linhas gerais busca-se criar um classificador de gestos de mão que seja treinado previamente e que então seja utilizado para classificar novas entradas de dados tanto em *offline* como em modo *online*. As sessões a seguir detalham os passos seguidos para se chegar ao reconhecimento dos gestos: definição das poses aceitas pelo sistema; especificação das etapas do projeto; obtenção dos dados de EMG; pré-processamento dos dados coletados; extração de características dos conjuntos de dados coletados; seleção das características de maior relevância; clusterização dos pontos projetados sobre as características mais relevantes; descrição da fase de treinamento e suas etapas; fase de classificação dos gestos; e por fim os resultados obtidos.

### 3.1 DEFINIÇÃO DOS GESTOS DE MÃO

Um dos objetivos deste trabalho é classificar gestos de mão baseado nos dados de sEMG. Para tanto é preciso antes definir quais são os gestos que o sistema deve ser capaz de reconhecer. A definição dos gestos foi guiada pela busca de movimentos que sejam utilizados em terapias e com leituras diferentes de EMG do antebraço, ou seja, encontrar gestos que possam ser separados pela leitura de EMG. Nove gestos foram escolhidos, além do gesto “descanso - *rest*”, que indica que nenhuma pose está sendo realizada, foram escolhidos (a) punho fechado - *fist*, (b) aceno para fora - *wave out*, (c) aceno para dentro - *wave in*, (d) mão espalmada - *spread*, (e) chifre - *horn*, (f) hang loose, (g) arma - *gun*, (h) legal - *thumb up*. A Figura 2.2 mostra fotos dos gestos.

### 3.2 ETAPAS DO PROJETO

O projeto consiste em duas fases principais, treinamento e classificação. Estas fases compartilham algumas etapas e também possuem etapas próprias. A fase de treinamento possui vários estágios iterativos de coleta de dados antes do treinamento em si. Para cada estágio de coleta de dados deve ser fornecido ao sistema os dados de entrada marcados, ou seja, cada conjunto de dados que representa um movimento deve estar acompanhado do nome da respectiva classe. Após coletar quantidade suficiente de dados, o treinamento é realizado. A fase de classificação ocorre tanto de forma *offline*, ou seja, após a execução de todos os movimentos o sistema determina qual a classe de cada movimento realizado, quanto *online*, modo em que o sistema reconhece os gestos em tempo real.

Uma vez definidos os gestos os quais o sistema deverá ser capaz de reconhecer, é preciso obter os dados de EMG para cada um destes movimentos. Ambas as fases se iniciam com a obtenção dos dados de EMG. A partir deste momento cada fase apresenta suas peculiaridades, mas mantendo algumas etapas em comum.

Na fase de treinamento, após obter os dados, estes devem ser marcados com a classe a que pertencem. Esta marcação consiste na criação de uma tabela que relaciona um conjunto de dados a uma das classes já definidas,



(a) punho fechado - *fist*



(b) aceno para fora - *wave out*



(c) aceno para dentro - *wave in*



(d) mão espalmada - *spread*



(e) chifre - *horn*



(f) hang-loose



(g) arma - *gun*



(h) legal - *thumb up*

Figura 3.1: Gestos de mão utilizados neste projeto. Cada gesto representa uma classe a ser treinada no classificador.

as quais o sistema é capaz de reconhecer. Em seguida os dados são pré-processados para posterior análise. O próximo passo é então extrair características fundamentais (*características*) dos conjuntos de dados. Diversas características são extraídas para cada canal, o que gera um enorme conjunto de dados contendo informações redundantes que podem ser filtradas. Portanto, em seguida é realizada a seleção de características relevantes ao processo de treinamento. Os conjuntos de dados marcados são então separados em grupos (*clusters*) baseado nas características selecionadas. Por fim, estes clusters são guardados em um repositório de dados.

A cada estágio de coleta de dados novos conjuntos de dados marcados são analisados e adicionados ao repositório de dados. Desta forma, após coletar e analisar uma quantidade razoável de dados, o repositório pode ser usado para o treinamento do classificador, o qual será utilizado na classificação de novos dados. Caso se deseje aumentar a quantidade de dados de treinamento basta incluir novos dados ao repositório e treinar o sistema novamente. A Figura 3.2 mostra as etapas da fase de treinamento.

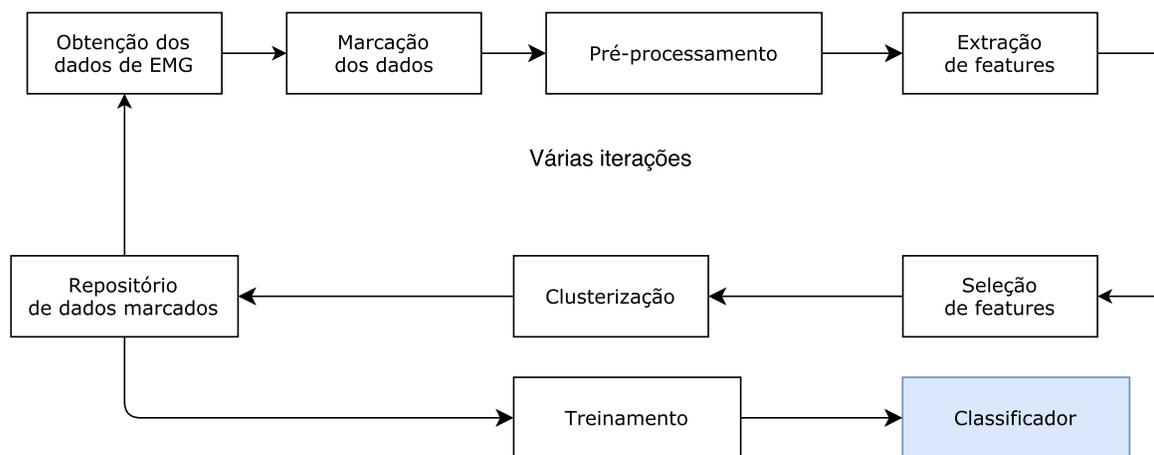


Figura 3.2: Etapas da fase de treinamento. A etapa inicial da fase de treinamento é a captura dos dados marcados. As iterações de captura, análise e armazenamento do dados marcados é realizada com várias pessoas. Ao fim das iterações inicia-se a etapa de treinamento.

Na fase de classificação, após obter os dados, estes são pré-processados para posterior análise. Da mesma forma que na fase de treinamento, o próximo passo é extrair características dos conjuntos de dados e em seguida é realizada a seleção de características. Os conjuntos de dados são então separados em clusters baseado nas características selecionadas. Uma vez separados os dados podem passar pelo classificador para que cada conjunto de dados de entrada seja associado a uma classe que o sistema reconhece. A Figura 3.3 mostra as etapas da fase de classificação.

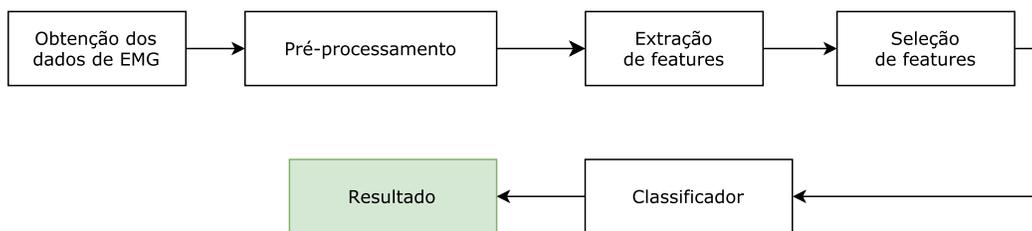


Figura 3.3: Etapas da fase de classificação. A etapa inicial da fase de classificação é a captura de novos dados. Assim que chegam os novos dados são analisados, classificados e uma classe é assinalada como resultado.

As sessões a seguir detalham cada uma das etapas do processo realizado neste trabalho, tanto para a fase de

treinamento quanto para a fase de classificação.

### 3.3 OBTENÇÃO DOS DADOS

Os dados de EMG utilizados neste trabalho são obtidos através da plataforma Myo Armband (MYO). Através da SDK disponibilizada pela Thalmic Labs, fabricante do Myo, e utilizando um *wrapper* em linguagem C++ é possível obter os dados disponibilizados pelo MYO em tempo real para serem trabalhados em alguma plataforma em C++.

Utilizando um arquivo MEX, os dados são levados ao MatLab também em tempo real. Um arquivo MEX permite que uma função de um código fonte escrito em C/C++ seja chamada pelo MatLab. Neste projeto o *wrapper Myo SDK MATLAB MEX Wrapper*, de autoria de Mark Tomaszewski, é utilizado para obter os dados do MYO para análise no MatLab. Para cada versão do MatLab uma lista de compiladores C/C++ é suportada. Neste projeto são utilizados MatLab R2012b com compilador Microsoft Visual C++ 2012 Professional.

O sinal de EMG de superfície é obtido pelo MYO por 8 canais a uma frequência de 200 Hz e normalizado entre os valores de -1 a 1. A Figura 3.4 mostra um exemplo dos dados obtidos.

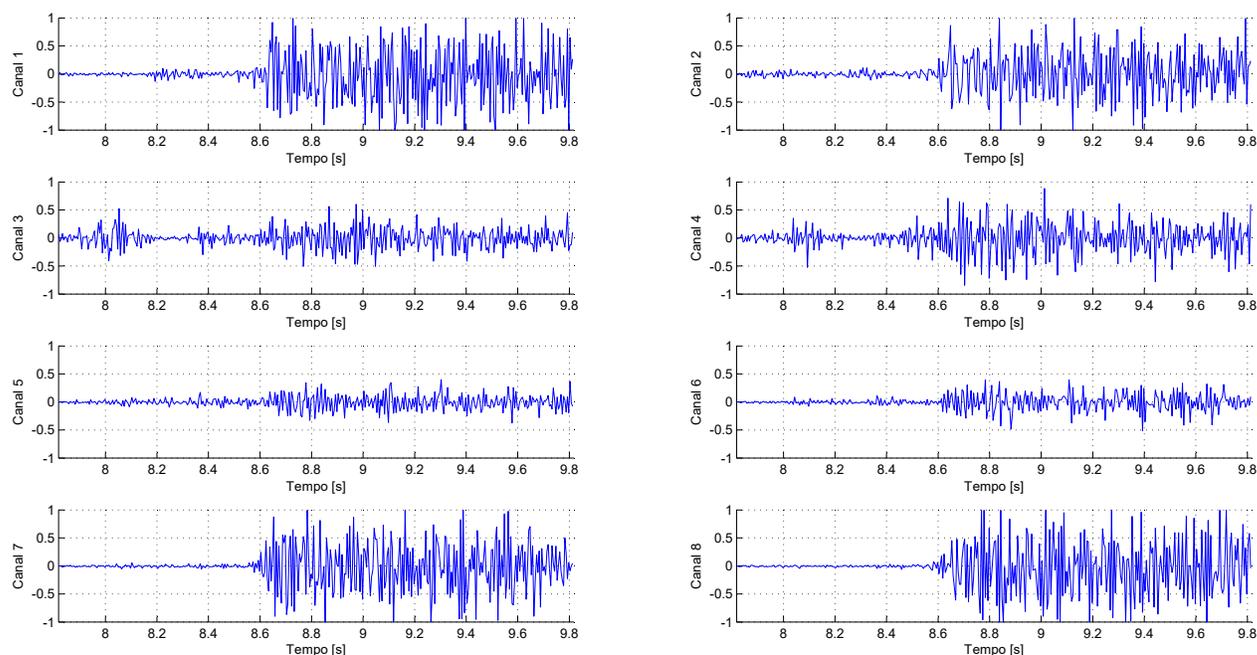


Figura 3.4: EMG extraído pelo Myo através de 8 canais independentes normalizado entre -1 e 1.

### 3.4 PRÉ-PROCESSAMENTO

Os dados de EMG obtidos passam então por uma etapa de pré-processamento cujo objetivo é isolar o sinal cru de ruídos e artefatos característicos deste tipo de sinal. O fabricante do MYO não especifica os tipos de filtros aplicados ao sinal recebido pela SDK para desenvolvedores, o sinal de sEMG obtido não é cru, já é recebido pré-processado e normalizado entre os valores -1 e 1. A etapa de pré-processamento portanto se resume ao janelamento, como mostra o diagrama da Figura 3.5.

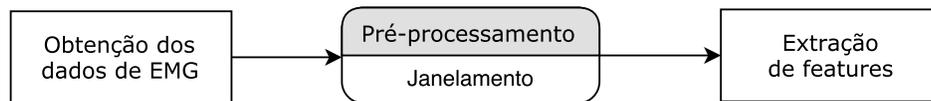


Figura 3.5: Diagrama da etapa de pré-processamento. Uma vez que o wrapper do myo já entrega os dados normalizados, esta etapa consiste simplesmente no janelamento temporal dos dados.

Janelamento é a separação dos dados obtidos em espaços de tempo deslizantes (*windows*) para a análise. Este passo busca extrair uma amostra pequena do sinal para que características específicas sejam extraídas e avaliadas. Desta maneira, fica também mais fácil a filtragem de ruídos. O janelamento pode variar sob alguns aspectos. É preciso definir os parâmetros iniciais, como o comprimento das janelas, definir se as janelas serão sobrepostas ou não ou se haverá espaçamento entre as janelas. A Figura 3.6 mostra os janelamento com sobreposição.

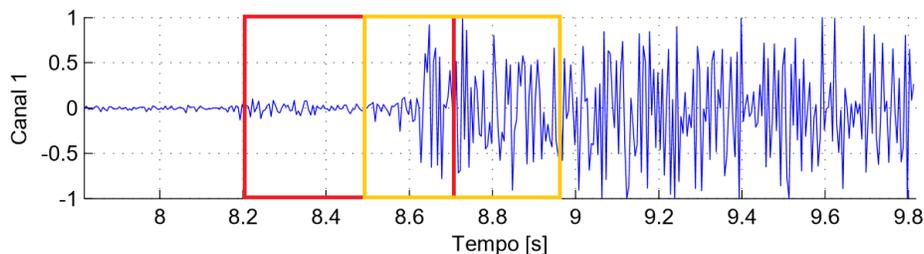


Figura 3.6: Janelamento temporal de EMG com sobreposição das janelas. As janelas compartilham parte da informação.

A Figura 3.7 mostra o janelamento sem sobreposição.

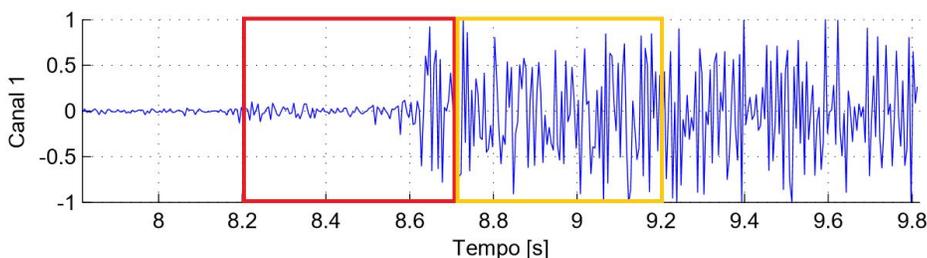


Figura 3.7: Janelamento temporal de EMG sem sobreposição das janelas. As janelas não compartilham nenhuma parte da informação.

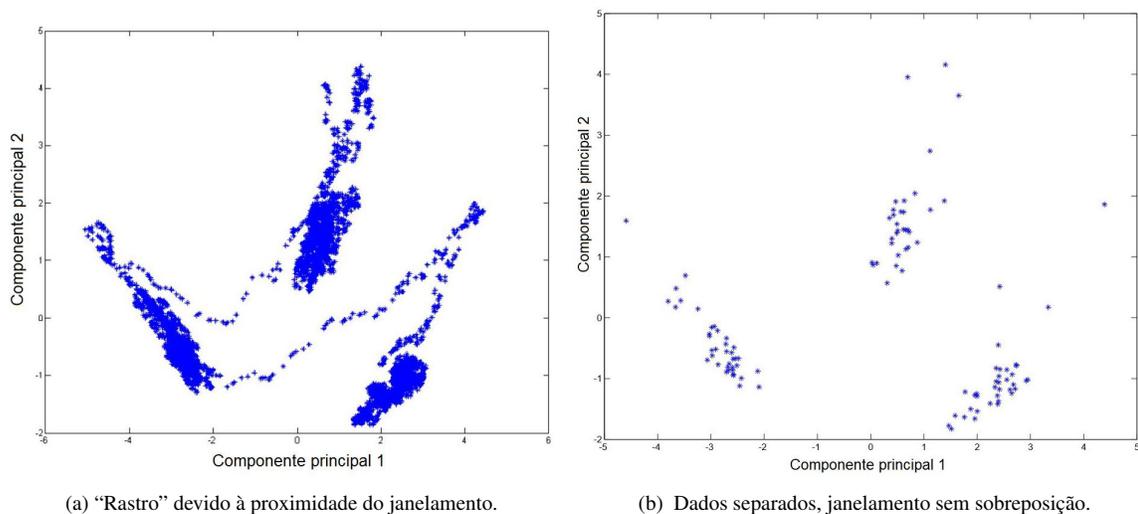


Figura 3.8: Dados de três movimentos projetados sobre as duas componentes principais obtidos pela técnica de PCA. O uso de janelamento com sobreposição com janelas muito próximas gera um rastro que prejudica o processamento dos dados.

Caso o janelamento seja muito granulado, ou seja, as janelas se sobrepondo e com defasagem pequena entre uma janela e outra, a tendência é que um "rastro" se forme após a análise por PCA e que a análise dos dados se torne muito demorada.

Para um teste com uma sequência de três movimentos, com um janelamento de tamanho 250 ms onde cada janela se move acrescentando o próximo registro após a janela e retirando o primeiro registro da janela. A análise dos dados durou 67,55 segundos e um "rastro" de dados aparece entre os clusters, como mostrado na Figura 3.8.

A Figura 3.8 também mostra o resultado da análise para os mesmos dados de entrada e com janelamento de mesmo tamanho, mas com janelas não sobrepostas. O tempo de análise foi de 5,84 segundos e os dados aparecem muito mais separados. Neste projeto utiliza-se o janelamento com 50% de sobreposição em janelas de 250ms de tamanho, o que corresponde a 50 amostras, pois a frequência de coleta de dados é de 200Hz.

### 3.5 EXTRAÇÃO DE CARACTERÍSTICAS

A etapa seguinte se trata de extrair características que representam as características do sinal. Algumas características apresentam variações muito claras ao realizar uma inspeção visual, como no caso da feature Valor Médio Quadrático (RMS), sobre a qual é possível visualizar nitidamente nove perfis, como mostrado na Figura 3.9.

Outra feature relevante é conhecida como envoltória, que consiste na obtenção do valor absoluto do sinal e filtragem passa-baixa, neste caso a 20 Hz. A Figura 3.10 mostra uma envoltória extraída de um teste para 9 movimentos.

Outras características só podem ser avaliadas analiticamente, pois visualmente não apresentam nenhum

padrão nítido, pois o gráfico parece difuso. A característica Skewness, mostrada na Figura 3.11, é um exemplo de uma característica cuja análise visual não é muito eficiente, mas os dados são relevantes, pois Skewness mede a simetria da distribuição estatística dos dados, o que ajuda a identificar padrões nos sinais de EMG.

Os dados de entrada para o cálculo das características são o resultado da etapa de pré-processamento, como mostra o diagrama da etapa de extração de características da Figura 3.12. Algumas características possuem peculiaridades, como a que calcula a quantidade de vezes que o sinal de EMG passa de positivo para negativo ou de negativo para positivo, a qual considera um pequeno limiar para não contabilizar flutuações em torno do zero (*zero crossing*). Outras exemplos de características analisadas são variância e *waveform change*, que avalia quanto o sinal varia de uma amostra para a anterior. Cada uma das características utilizadas é calculada para cada janela para cada canal. Uma vez que são utilizados 8 canais e calculadas 9 características para  $W$  janelas, o resultado é uma matriz de características de tamanho  $W \times 72$ , ou seja, uma matriz de dimensão 72.

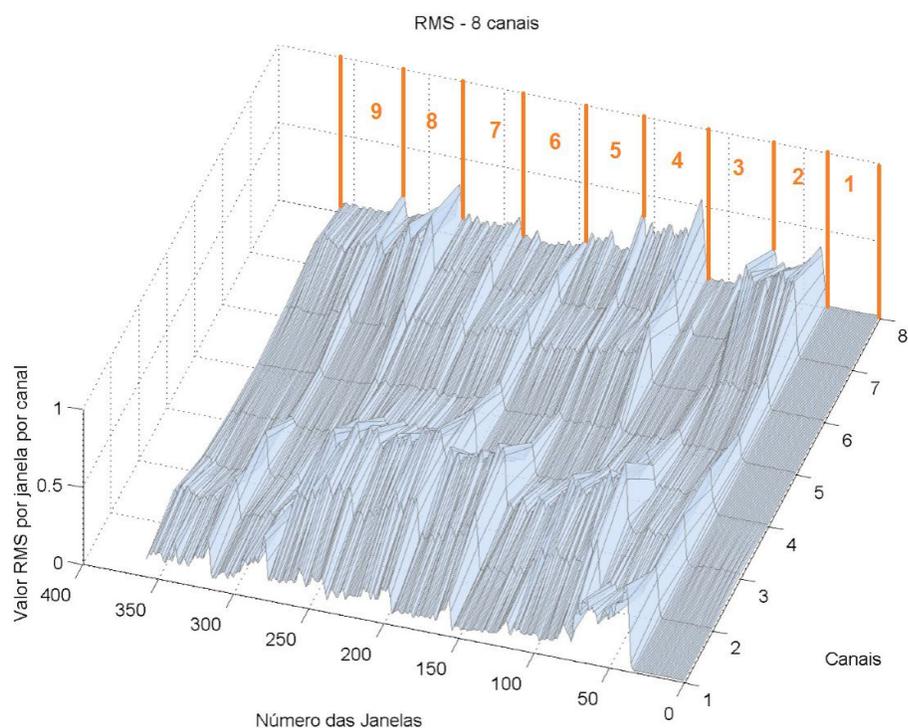


Figura 3.9: Característica extraída - Valor RMS para cada janela por canal. Nesta figura é possível visualizar as regiões dos nove gestos.

### 3.6 SELEÇÃO DE CARACTERÍSTICAS

Nesta etapa, o objetivo é escolher características de forma a evitar redundância de informação a fim de reduzir a quantidade de dados a ser processado. Esta etapa é muito importante, pois quanto menor a quantidade de valores na entrada, sem que se perca a informação essencial, reduz a complexidade do processo de classificação, tornando-o mais ágil. As entradas descartadas devem ser aquelas com ruído, ou seja, dados que aparentemente tem correlação com a saída, mas na verdade não possuem, bem como as entradas que de fato

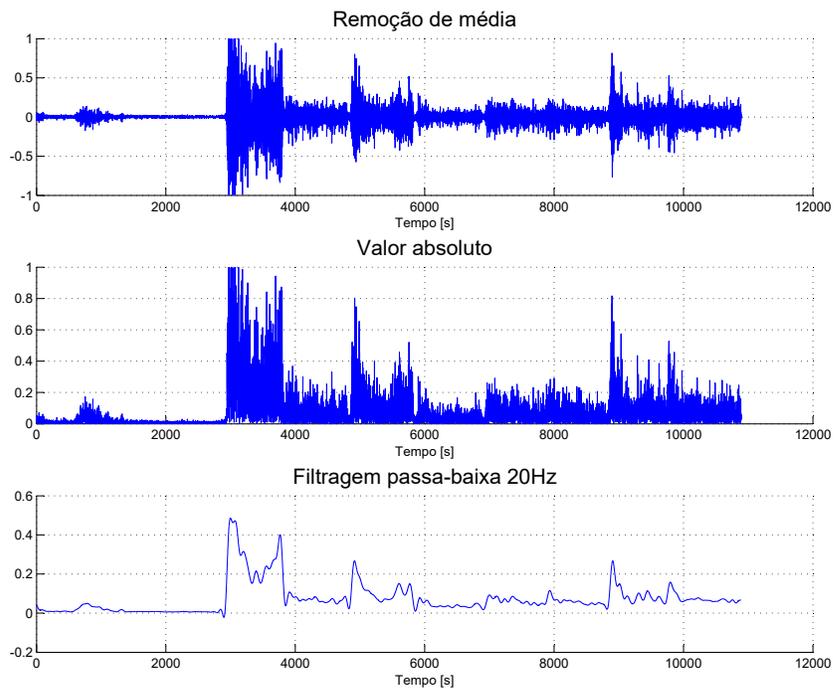


Figura 3.10: Característica extraída - Envoltória.

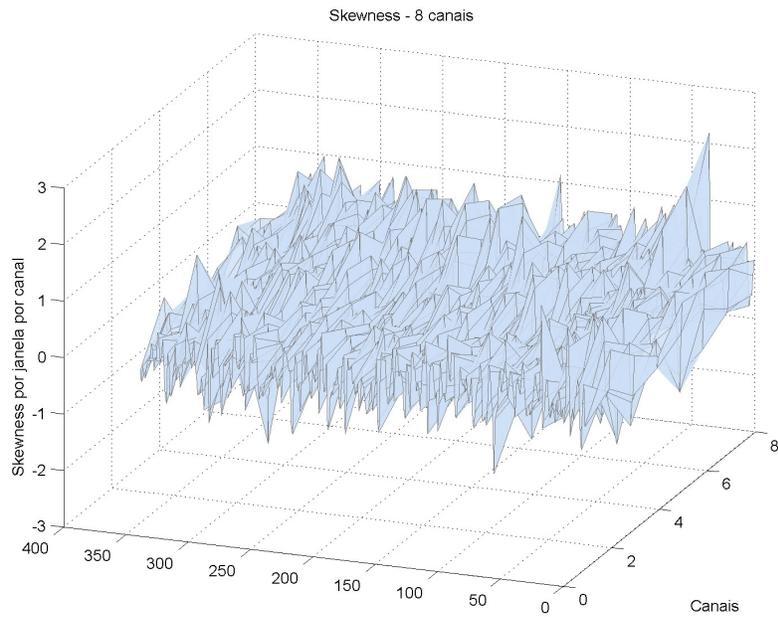


Figura 3.11: Característica extraída - Skewness.

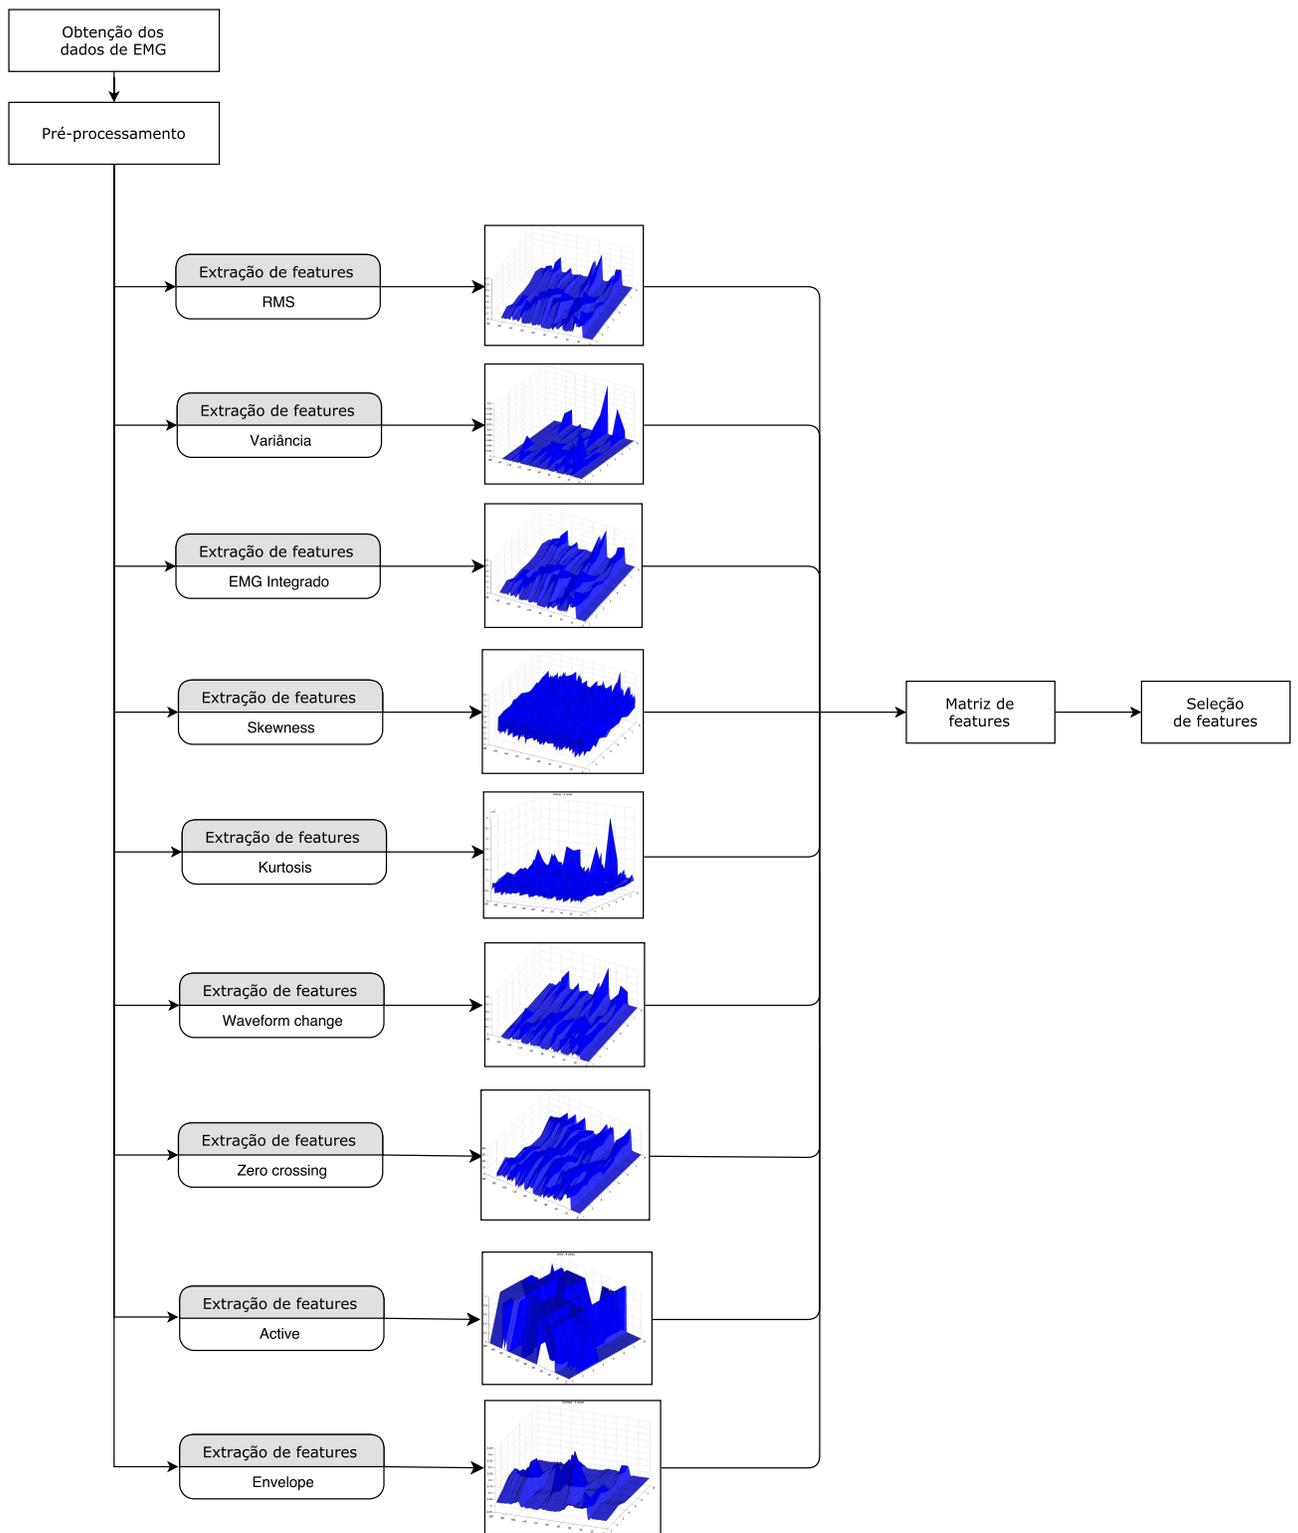


Figura 3.12: Diagrama da extração de características.

possuem pouca ou nenhuma correlação com a saída.

Uma forma de seleção de características é através da técnica de Análise de Componentes Principais, pela qual um conjunto de dados que possivelmente apresenta correlação é transformado e um conjunto menor de dados expresso em dimensões ortogonais. Tratando-se de dados de EMG, cada feature para cada canal que transmite um conjunto de dados eletromiográficos evoluindo com o tempo captados por um sensor representa uma dimensão a ser avaliada.

No caso deste projeto a técnica de PCA não é aplicada diretamente sobre o sinal de EMG, mas sobre as características temporais extraídas do sinal de EMG. A seleção das características é realizada sobre uma matriz com dimensão 72. O diagrama da Figura 3.13 detalha a etapa de seleção de características.

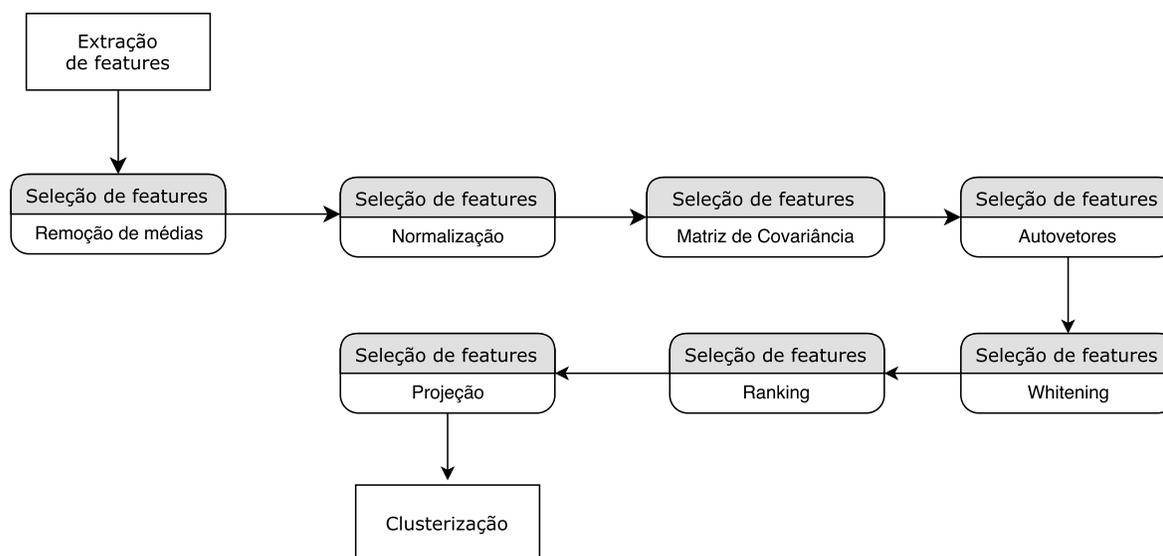


Figura 3.13: Diagrama da etapa de seleção de características.

A matriz de características tem a média retirada e o resultado, para cada dimensão, é normalizado dividindo os valores pela variância do conjunto de dados. Então, a matriz de covariância entre as 72 dimensões é calculada. Em seguida, os autovetores e os respectivos autovalores da matriz de covariância são calculados. Por fim, os autovetores são normalizados utilizando a técnica de *PCA Whitening*.

Componente	Contribuição Individual	Acumulado
PC 1	41,52%	41,52%
PC 2	29,38%	70,90%
PC 3	16,43%	87,33%
PC 4	6,02%	<b>93,35%</b>
PC 5	1,93%	95,28%
PC 6	1,18%	96,46%
PC 7	0,85%	97,31%
PC 8	0,82%	98,13%
PC 9	0,70%	98,83%

Tabela 3.1: Contribuição percentual acumulada das componentes principais para um teste com 5 gestos.

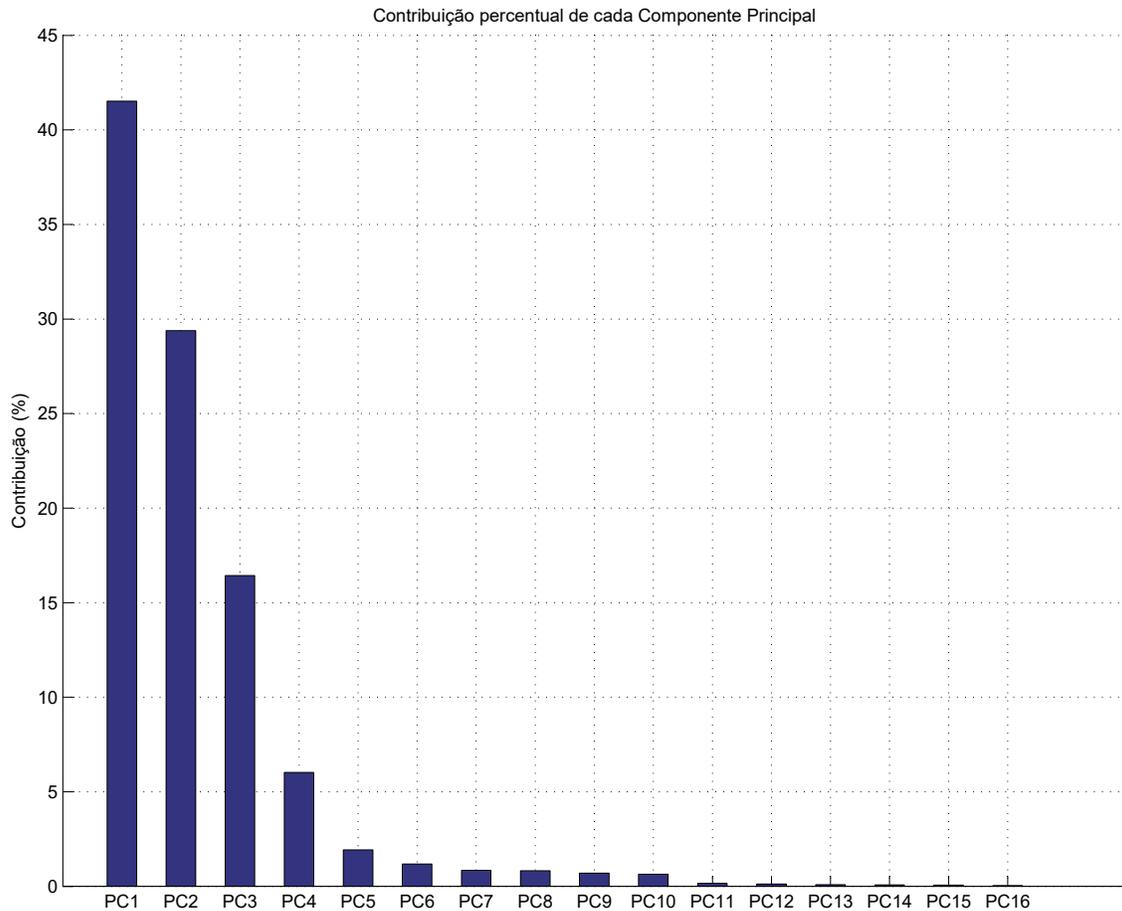


Figura 3.14: Contribuição percentual das componentes principais para teste com 5 gestos.

Os autovetores são as componentes principais, ou seja, as dimensões ortogonais com maior variância para este conjunto de dados. Os respectivos autovalores são utilizados para o ranking das dimensões mais relevantes, quanto maior o autovalor, maior é a contribuição do respectivo autovetor na representação das características neste novo espaço de menor dimensão. A seleção de quais componentes serão utilizadas é realizada verificando, a partir das características com maior contribuição, aquelas que juntas contribuem com 90% ou mais, as demais componentes são descartadas. O limiar de 90% foi escolhido pois para os testes com nove gestos as quatro primeiras componentes sempre representaram mais de 90% da informações, e a partir da quinta componente ocorre um decaimento mais lento. Para um teste realizado com 5 gestos (descanso, punho fechado, aceno para fora, aceno para dentro e chifre), a contribuição percentual das componentes mais relevantes é mostrada na Figura 3.14. Neste caso, apenas as 4 componentes principais de maior contribuição são utilizadas, pois juntas representam 93,35% da informação, conforme detalhado na Tabela 3.1.

Note que as 72 dimensões iniciais foram reduzidas para 4 dimensões. Projetando as características sobre as três componentes principais é possível visualizar claramente que os dados se dividem em cinco grupos, como mostra a Figura 3.15. Ao se projetar os dados sobre as componentes principais 1 e 2, também é possível verificar o agrupamento dos dados, como mostra a Figura 3.16.

Características sobre as componentes principais 1, 2 e 3

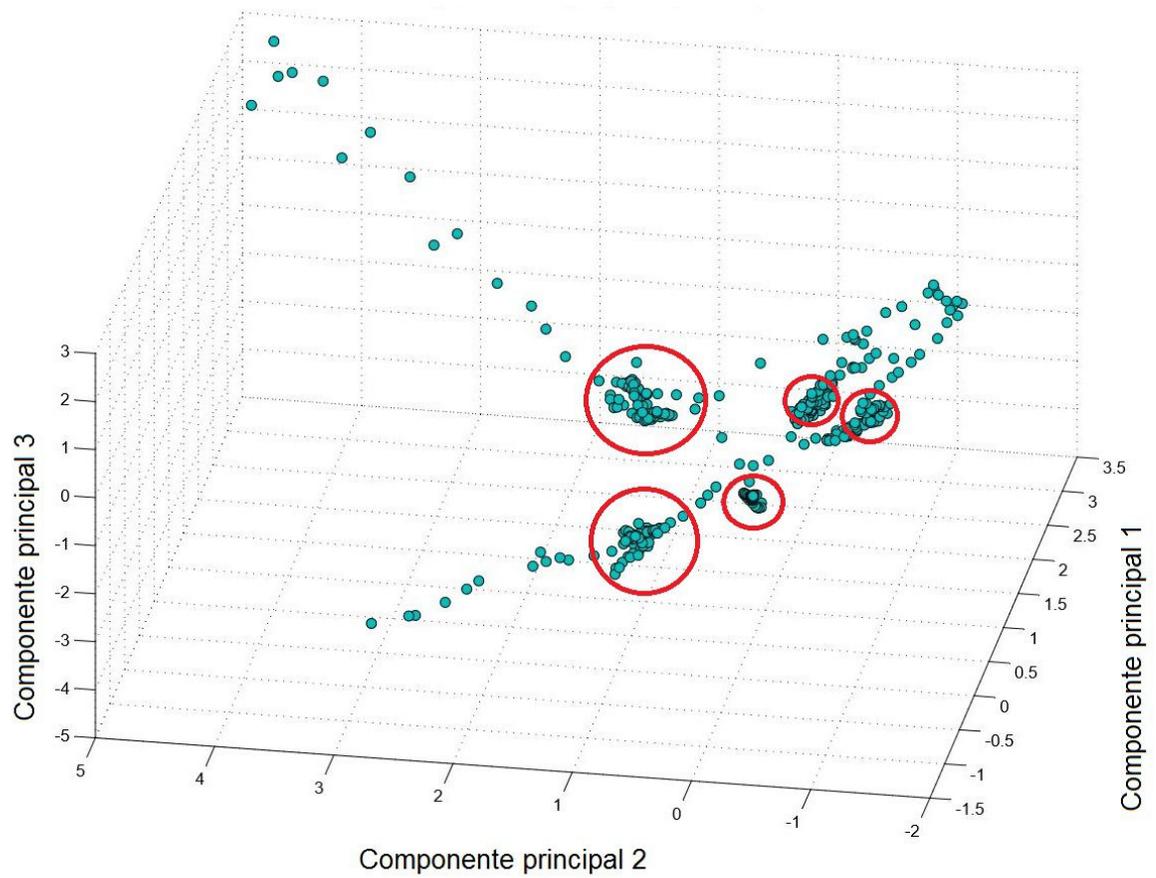


Figura 3.15: Características projetadas sobre as componentes principais 1, 2 e 3. 5 gestos.

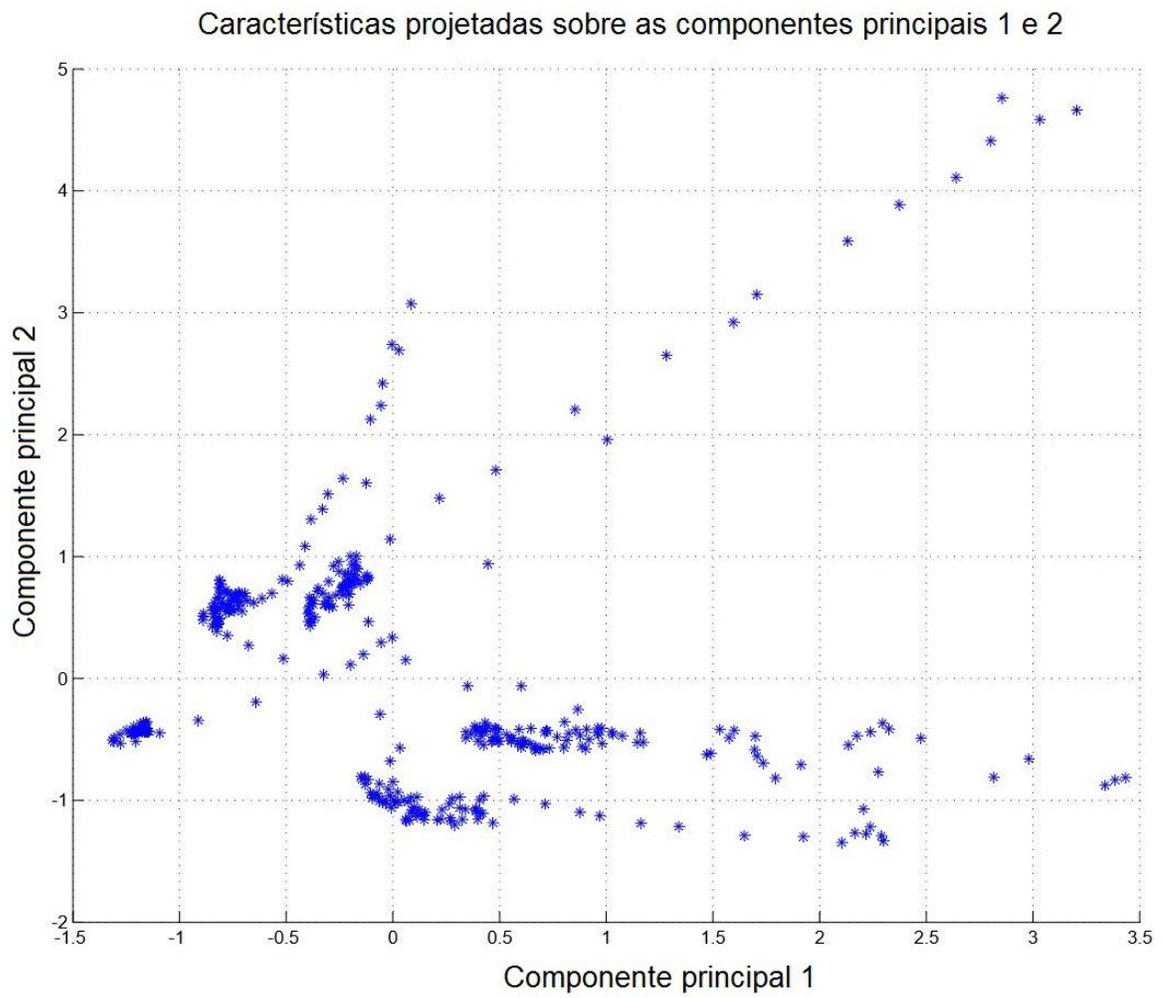


Figura 3.16: Características projetadas sobre as componentes principais 1 e 2. 5 gestos.

### 3.7 CLUSTERIZAÇÃO

Esta etapa é própria da fase de treinamento. As componentes principais escolhidas para o novo espaço de menor dimensão são as características selecionadas. Após a projeção dos dados sobre as componentes principais selecionadas, o passo seguinte é agrupar os pontos com características semelhantes. Para tanto é utilizada a técnica k-means para clusterização.

É importante lembrar que esta etapa é necessária apesar dos dados já estarem marcados com a classe a que pertencem. Isto se dá pois os dados que representam uma classe, ou seja, um gesto, são na verdade características calculadas dentro de janelas temporais. Desta maneira, as janelas captam todas as fases do movimento, desde seu transiente inicial, passando pela manutenção do gesto e a estabilidade relativa do sinal e terminando com o transiente de finalização ou troca de gesto. O resultado deste processo de análise em janelas de tempo é que alguns pontos se espalham bastante, gerando pontos fora do padrão da classe a que foi marcado (*outliers*). Para fins de classificação, o que mais importa é a região onde os pontos de uma classe se concentram com maior frequência. Portanto, faz-se essencial separar os dados projetados em clusters, eliminando com maior precisão possível os outliers gerados por transientes no início, mudança ou fim dos gestos, e obtendo os centróides e pontos mais significativos que representam cada classe para serem utilizados no treinamento.

A técnica k-means se inicia com a escolha da quantidade de classes a ser separadas. Esta tarefa deve ser bem realizada, ou pode levar a um agrupamento incorreto dos dados. Apesar de já se saber a quantidade de cluster, que deve a mesma quantidade de movimentos, o algoritmo não funcionará bem se apenas “souber” que deve encontrar um número definido de grupo, pois, uma vez que utiliza um cálculo de distância entre cada ponto e os centróides de cada classe, o algoritmo provavelmente juntaria duas classes com centróides próximos, mas cujos membros internos possuam pouca variância do centróide, ou seja, estão todos muito perto, ou separaria em mais de uma classe aqueles pontos de uma classe com grande variância, ou seja, com dados mais espalhados. Ambos os casos supracitados ocorrem neste projeto. O resultado de utilizar técnicas convencionais de clusterização por k-means seria a subdivisão em classes que não corresponderiam às classes reais dos dados, algumas classes contendo muito mais dados que deveria, e outras classes contendo dados de uma única classe real de um gesto.

A Figura 3.17 mostra o resultado de uma clusterização por k-means utilizando o método tradicional para todos os 9 gestos, a Figura mostra a projeção dos dados sobre as duas principais dimensões apenas. É possível observar que outliers foram identificados em várias classes, clusters 2, 3, 4, 6 e 7, bem como uma classe de um gesto foi dividida em duas classes, clusters 1 e 2. Também, ocorreu o caso em que dois gestos foram unificados em único cluster, cluster 3. Além disso, é possível verificar que os pontos das classes 4 e 7 foram agrupados corretamente, mas alguns pontos de uma classe estão muito próximos da região de outra classe, tornando o processo de classificação mais complexo. A Figura 3.18 mostra o resultado de uma clusterização por k-means utilizando o método tradicional para os 5 gestos testados na sessão anterior, e também mostra a projeção dos dados sobre as duas principais dimensões apenas. Note que o resultado para 5 gestos não é tão ruim, mas ainda é possível verificar outliers no cluster 1 bem como pontos muito próximos entre os clusters 2 e 5 e os clusters 3 e 4, fatores que dificultariam o treinamento e consequentemente a classificação.

Desta forma, este trabalho propõe uma abordagem inovadora para trabalhar a clusterização dos pontos projetados sobre suas componentes principais. Uma vez que os dados estão marcados, sabe-se que o objetivo final é encontrar uma quantidade de clusters igual à de classes existentes. Inicia-se este processo selecionando uma quantidade superior de clusters do que se busca de classes. Para este projeto foi selecionada a quantidade inicial de 20 clusters. Em seguida é feita uma verificação de segurança: caso a quantidade de dados amostrados

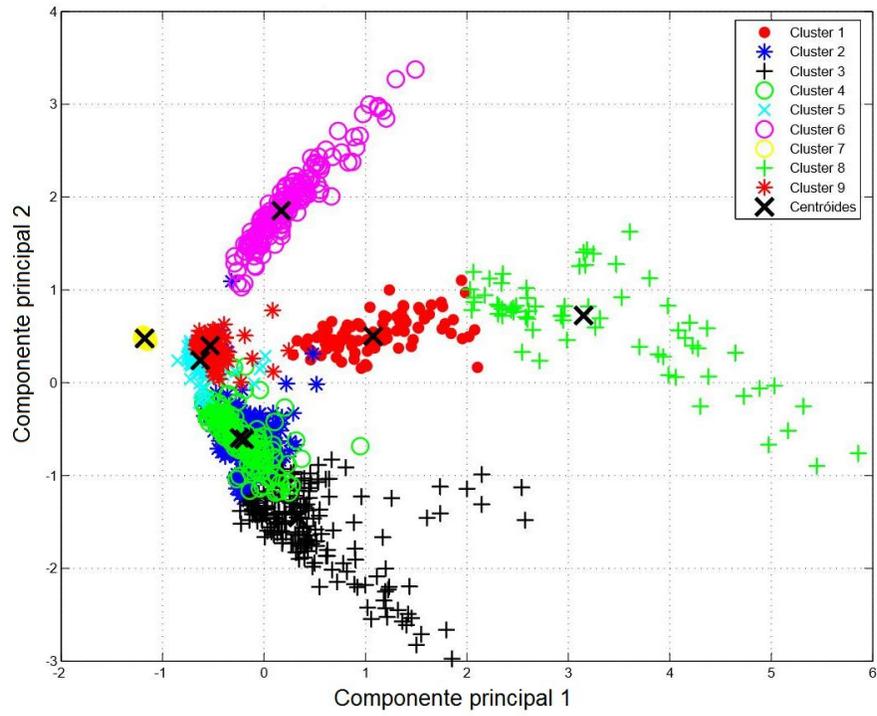


Figura 3.17: Resultado da clusterização convencional por k-means para 9 gestos.

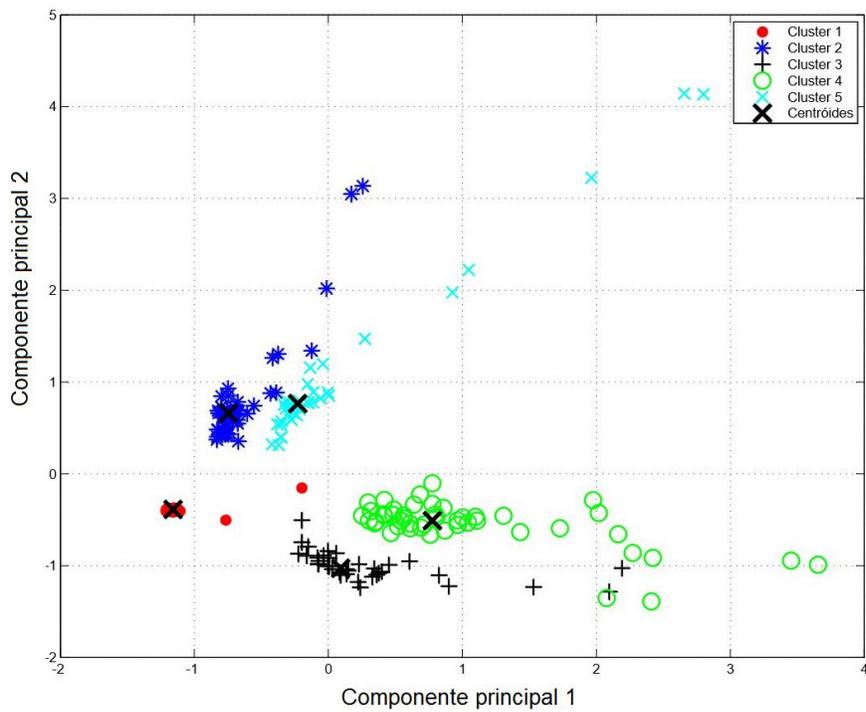


Figura 3.18: Resultado da clusterização convencional por k-means para 5 gestos.

seja menor que a quantidade de clusters a quantidade de clusters de início é reduzida até a quantidade de amostras. Se a quantidade de amostras for menor que a quantidade de classes que se deseja classificar o processo não pode ser realizado.

O próximo conjunto de passos é iterativo. A condição de parada para este loop é ter encontrado a quantidade de clusters desejada sendo que cada cluster deve estar a uma distância mínima um do outro. Inicia-se a iteração com a definição da distância mínima aceita entre os clusters. Este valor varia conforme a quantidade de clusters a ser encontrados na iteração, o qual é 20 na primeira iteração. Quanto maior o número de clusters menor é a distância mínima entre eles, pois com muitos clusters é maior a probabilidade deles estarem mais próximos do que com poucos clusters. Após vários testes, dependendo das características e da quantidade de dimensões que o novo domínio terá (domínio das componentes principais), este valor deve ser ajustado, mas em geral fica em torno de 0,3 a 1,5.

Então, é realizado o processo de clusterização pelo método k-means. A inicialização é feita utilizando a técnica k-mean++. O principal objetivo do método de clusterização por k-means é minimizar a soma das distâncias entre os pontos e o centróide do respectivo cluster. A medida de distância utilizada na função de custo a ser minimizada é feita pela métrica *cityblock* devido a seu melhor desempenho computacional, conforme [51]. Enquanto a distância euclideana busca o caminho mais curto entre dois pontos caminhando pelas hipotenusas se for considerado um plano bidimensional, a métrica *cityblock* tem esse nome pois calcula distâncias à maneira em que se caminha pelas quadras de uma cidade, pelos catetos. Portanto, a métrica *cityblock* calcula a soma do valor absoluto das diferenças entre as componentes de cada ponto. A equação  $\sum_{j=1}^k |a_j - b_j|$  modela a métrica *cityblock*, onde  $a$  e  $b$  são os pontos para os quais se deseja calcular a distância e  $k$  é o conjunto de dimensões destes pontos.

A clusterização por k-means é aplicada em três fases. Na fase primeira fase vários pontos são mudados para outro cluster simultaneamente, as distâncias são calculadas. Na segunda fase cada ponto é movido para outro cluster individualmente, novamente as distâncias são calculadas, de modo que um mínimo local é encontrado. A terceira fase consiste em uma heurística para a resolução ideal, na qual os processos anteriores são repetidos exaustivamente, neste caso por 30 vezes, com inicializações diferentes com o objetivo de encontrar o mínimo global da função custo do k-means.

Voltando ao passo iterativo do método proposto, segue-se para a etapa seguinte. Nesta etapa para cada cluster é calculado a distância entre ele e os demais clusters. Para esta medida de distância é utilizada a métrica euclideana, a qual usa como referência os centróides de cada cluster. Caso existam clusters muito próximos um do outro, ou seja, com distância entre eles menor que a distância mínima entre os clusters especificada no início do processo, a quantidade de cluster é reduzida em  $um$  ( $q = q - 1$ ) e o passo iterativo é reiniciado. Esta etapa é importante para evitar que uma classe de pontos que representa um gesto seja dividida em mais de um cluster muito próximos um do outro.

Caso não exista clusters muito próximos o passo iterativo segue. Então, é feita a verificação da existência de clusters com poucos pontos. A referência de quantidade mínima de pontos é definida como um quarto da média da quantidade de pontos por clusters, ou seja  $min = \frac{N}{4C}$ , onde  $N$  é a quantidade total de pontos avaliados e  $C$  é a quantidade de clusters desta iteração. O objetivo desta etapa é eliminar outliers, os quais eventualmente são classificados em clusters artificiais com poucos pontos. Se existirem clusters artificiais, os pontos destes clusters são eliminados da análise, a quantidade de cluster é reduzida em  $um$  ( $q = q - 1$ ) e o passo iterativo é reiniciado.

Na hipótese de não haver clusters artificiais, a fase iterativa segue para uma segunda verificação de outliers. Nesta etapa busca-se pontos que tenham sido classificados erroneamente, ou seja, uma vez que os dados foram

marcados com a classe a que pertencem eles podem ser identificados e removidos caso não estejam inseridos no cluster correto. Novamente, o objetivo desta etapa é remover outliers que possam ter sido causados por janelas próximas ao início ou fim dos gestos, causando transitórios nas características do sinal de EMG. Estes outliers podem atrapalhar no posicionamento dos centróides e consequentemente na fase de treinamento.

A Figura 3.19 mostra o histograma dos pontos para o teste com 5 gestos. Observe que os clusters cujos pontos apresentam menor variância em torno do centróide, ver Figura 3.21, possuem mais pontos que os demais, isto ocorre pois os clusters que se “comportam pior” tiveram alguns outliers removidos.

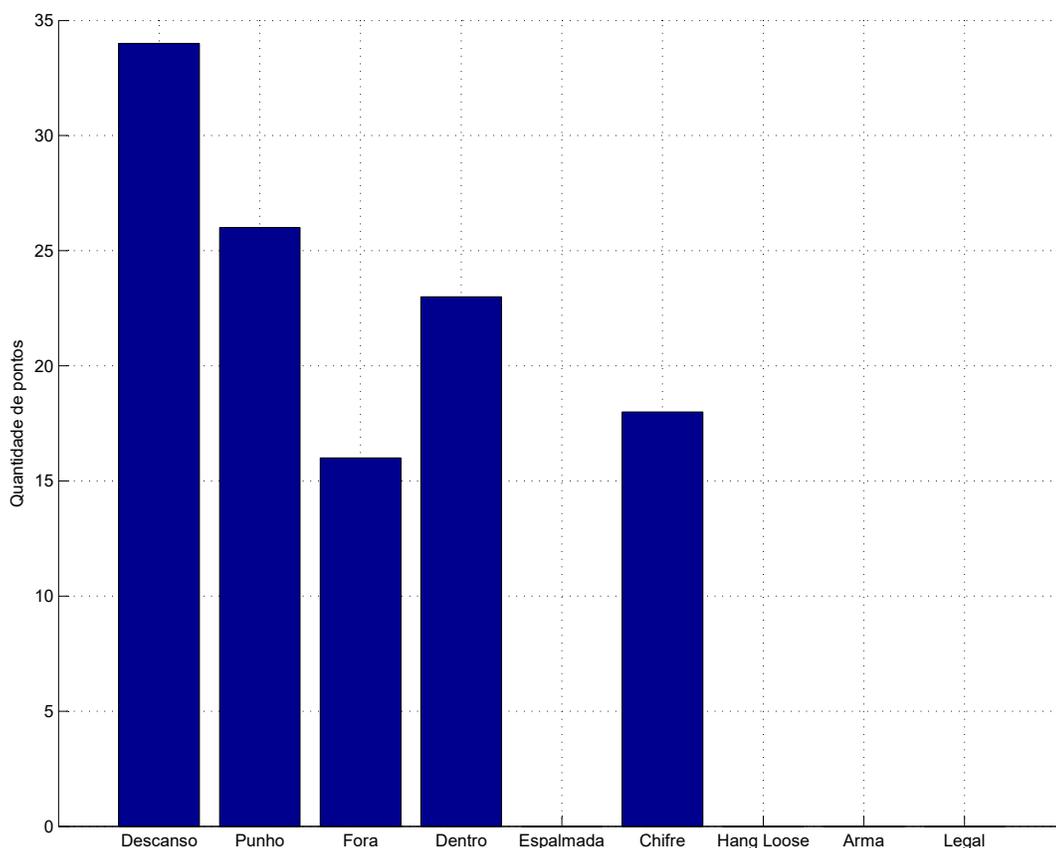


Figura 3.19: Histograma para 5 gestos.

Em seguida, caso nenhuma das etapas acima ocorra, verifica-se se a quantidade de clusters é igual à quantidade final desejada de clusters. Se ainda for maior a quantidade de cluster é reduzida em  $um$  ( $q = q - 1$ ) e o passo iterativo é reiniciado.

Por fim, caso nenhuma das etapas acima ocorra, ou seja, a clusterização está definida, os pontos que estão muito distantes do centróide de sua própria classe são eliminados. Este valor também precisa ser ajustado dependendo das características utilizadas e da quantidade de dimensões que o novo domínio terá (domínio das componentes principais). O objetivo desta etapa é definir regiões mais claras decisão, evitando pontos muito próximos das fronteiras entre uma classe e outra, o que facilita tanto o treinamento quanto a classificação.

Uma vez finalizado o passo iterativo tem-se o resultado final da clusterização. A Figura 3.20 mostra o resultado de uma clusterização por k-means utilizando o método proposto para todos os 9 gestos, a Figura mostra a projeção dos dados sobre as duas principais dimensões apenas, de forma que pode parecer que pontos

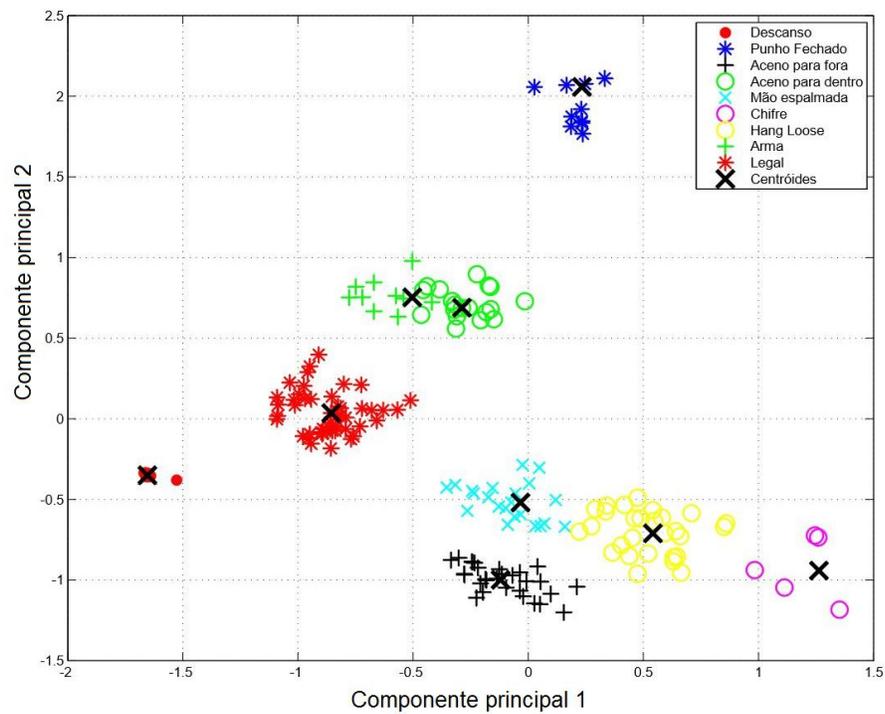


Figura 3.20: Resultado do método proposto para clusterização por k-means para 9 gestos.

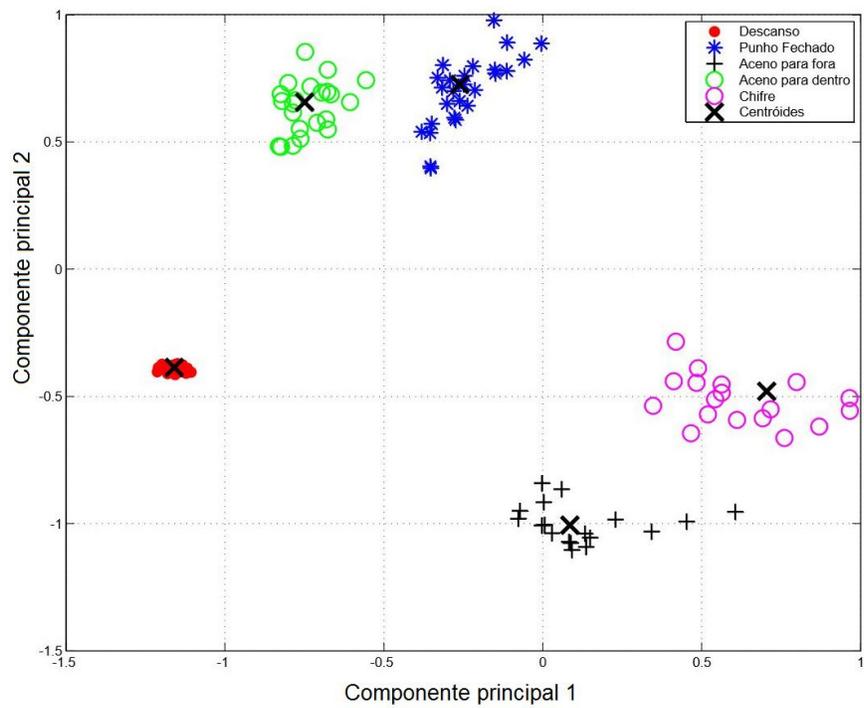


Figura 3.21: Resultado do método proposto para clusterização por k-means para 5 gestos.

de diferentes clusters ocupam a mesma região, enquanto na verdade existe distanciamento entre os clusters em outra dimensão não considerada. Note que mesmo utilizando o método proposto algumas regiões ainda apresentam fronteiras muito próximas, isto ocorre pois alguns movimentos de fato são muito similares em termos dos sinais de sEMG gerados, o que dificulta muito a diferenciação destes gestos durante o treinamento e classificação.

A Figura 3.21 mostra o resultado de uma clusterização por k-means utilizando o método proposto para os 5 gestos testados na sessão anterior, e também mostra a projeção dos dados sobre as duas principais dimensões apenas. Note que o resultado para 5 gestos sofre relevante melhora. Os clusters apresentam excelente separação mesmo considerando apenas as duas principais dimensões, os outliers foram removidos e as regiões estão bem definidas, o que favorece as fases de treinamento e de classificação.

### 3.8 TREINAMENTO

A fase de treinamento utiliza diretamente os resultados obtidos pela clusterização. Os cluster e seus centróides servem de base para a separação das regiões de cada classe que representa um gesto. O problema de classificação de gestos é do tipo multi classe, ou seja, um conjunto de dados de entrada referente a um gesto deve ser assinalado a uma das nove classes de gestos que o sistema reconhece. Entretanto, neste projeto a tarefa é dividida em vários problemas menores, e faz-se uso de um conjunto de classificadores binários em sequência. O objetivo desta divisão de tarefas é que os classificadores gerados não são muito complexos, resultando em decisões rápidas durante seu uso e projetos mais simples com abordagens personalizadas para cada classificador em tempo de desenvolvimento.

Uma MBT é uma ferramenta que implementa a abordagem de estender problemas binários para um problema multi classe. Cada nó interno da árvore é um ponto de decisão com duas saídas possíveis. Os nós folha são as diversas classes reconhecidas pelo classificador. O uso desta ferramenta foi definido por seu desempenho computacional. O tempo de classificação é curto o suficiente para uma aplicação *online*, ou seja, os gestos são classificados em tempo de execução.

A MBT utilizada possui nós de decisão do tipo “um contra resto”, o que significa que em cada nível de decisão o resultado será ou uma classe ou as classes que ainda restam nos níveis abaixo. Caso o resultado seja uma classe, os pontos classificados são removidos e não prosseguem para os próximos níveis da árvore. Esta MBT gerada será uma árvore desbalanceada devido aos critérios intrínsecos à sua formação. No caso deste trabalho, como são nove as classes de gestos as quais o sistema é capaz de reconhecer, oito classificadores binários devem ser treinados.

Portanto, a tarefa de treinamento consiste na construção de uma árvore binária de decisão, que é o classificador a ser utilizado na fase de classificação. Este classificador é do tipo hierárquico, pois após cada nível de decisão que se aprofunda na árvore restam menos pontos a serem classificados nos próximos níveis.

O primeiro passo do treinamento é escolher a sequência na qual os gestos serão classificados. Para tanto observa-se o gráfico dos pontos projetados sobre duas dimensões. No caso do teste de exemplo que vem sendo utilizado neste capítulo para 5 gestos, ver Figura 3.21, pode-se observar que alguns gestos estão mais concentrados próximo ao centróide do cluster a que pertencem, já outros gestos apresentam distribuição mais espalhada, com pontos de um mesmo cluster distantes um do outro. Os clusters mais fáceis, ou seja, distante de outros clusters ou com pontos muito concentrados, devem ser considerados antes dos demais clusters, pois com

menos dados os classificadores mais profundos podem ser mais simples. Em linhas gerais busca-se encontrar um arranjo em que seja necessário os classificadores mais simples possíveis de forma a reduzir ao máximo o tempo de classificação.

O classificador de 5 gestos é definido com a seguinte sequência de classificadores: descanso contra resto; aceno para fora contra resto; aceno para dentro contra resto; punho fechado contra chifre. Note que para separar 5 classes são necessários 4 classificadores. A Figura 3.22 mostra um diagrama da MBT para 5 gestos. A sequência dos testes é definida pela dificuldade dos testes. Os testes mais fáceis são realizados inicialmente, e os mais complexos para o final, de forma que, eliminando as possibilidades anteriores os testes se tornem menos complexos.

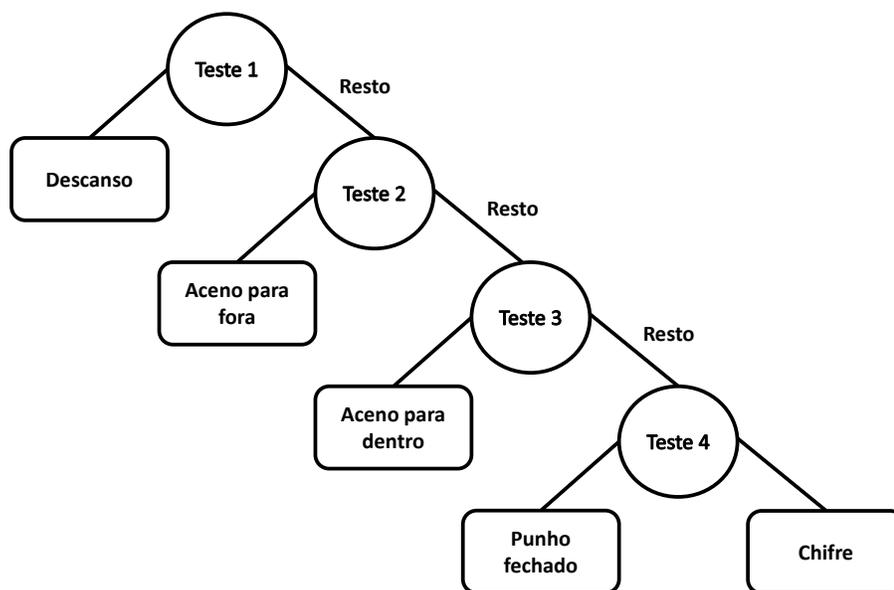


Figura 3.22: Árvore binária multi modal para 5 gestos. Os testes mais fáceis são realizados inicialmente, os mais complexos no final.

### 3.8.1 Classificadores binários

O segundo passo da etapa de treinamento é o projeto de cada um dos classificadores binários. Uma técnica muito eficiente para separação de pontos em duas classes consiste no uso de Máquinas de Vetores de Suporte (*Support Vector Machine - SVM*). Uma SVM é um método de aprendizagem supervisionado e portanto deve ser treinada antes de ser utilizada como classificador. Alguns destes problemas de classificação não podem ser eficazmente solucionáveis por hiperplanos lineares, para estes casos a SVM pode ser treinada com um kernel não linear, como quadrático, polinomial, gaussiano radial, redes neural com percéptrons em várias camadas, ou mesmo um kernel personalizado. Desta forma, cada nó da MBT se caracteriza por uma SVM previamente treinada com um kernel específico. Abaixo estão os classificadores treinados para o teste 5 gestos utilizado neste capítulo.

O primeiro classificador é o “descanso contra resto”. Uma vez que os dados desta classe possuem variância muito pequena um kernel do tipo gaussiano radial foi selecionado para este classificador, pois o objetivo é

criar uma região circular em torno do centróide. Este nó de classificação é considerado o mais fácil devido à distribuição concentrada dos pontos e à distância relativa dos outros clusters, por isso este é o nó raiz. A Figura 3.23 mostra a SVM do teste 1 para 5 gestos em duas dimensões, a SVM utilizada para classificação considera todas as dimensões dos pontos. A Figura 3.24 mostra a região da SVM do teste 1 para 5 gestos.

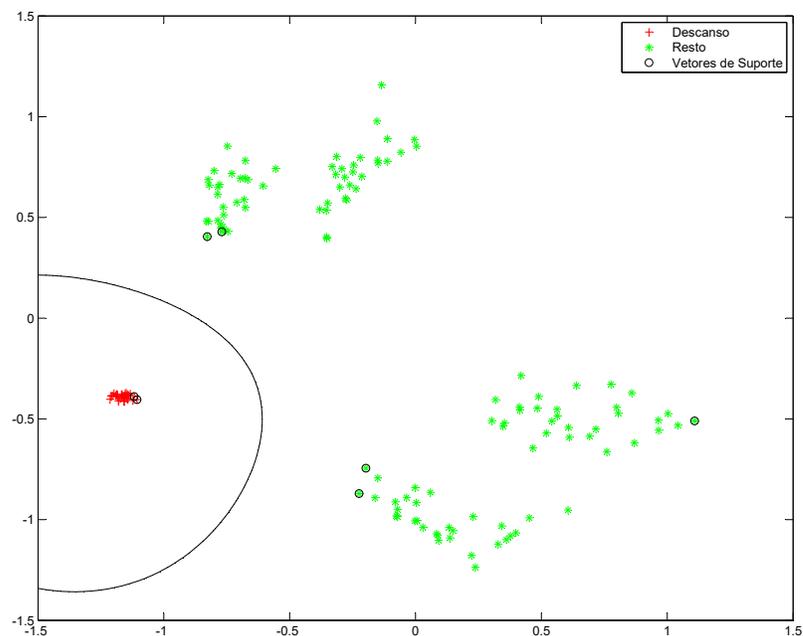


Figura 3.23: SVM do teste 1 - descanso contra resto - 5 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.

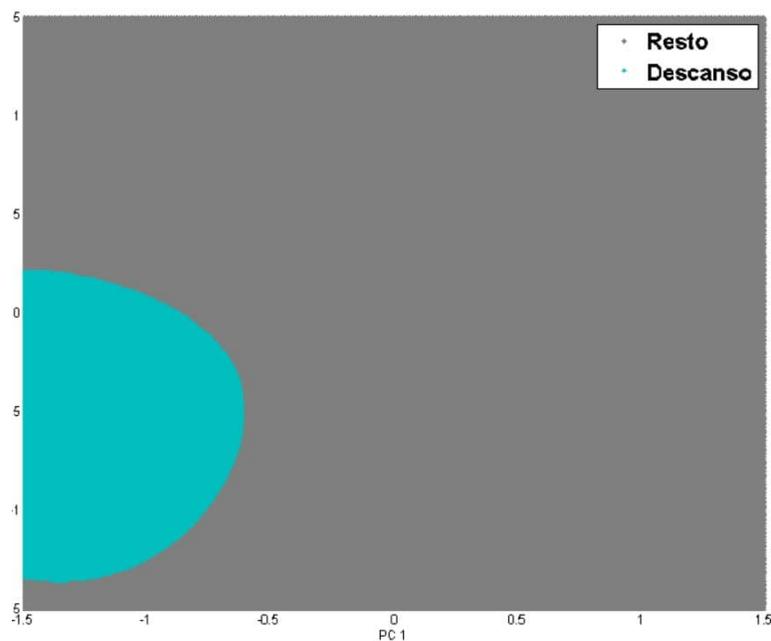


Figura 3.24: Região da SVM do teste 1 - descanso contra resto - 5 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.

O segundo classificador é o “aceno para fora contra resto”. Os dados desta classe possuem maior variância em relação ao primeiro classificador. Uma vez que os dados deste cluster estão espalhados na horizontal e a região de separação desejada também tem perfil horizontal, um kernel do tipo linear foi selecionado para este classificador. A Figura 3.25 mostra a SVM do teste 2 para 5 gestos em duas dimensões, a SVM utilizada para classificação considera todas as dimensões dos pontos. A Figura 3.26 mostra a região da SVM do teste 2 para 5 gestos.

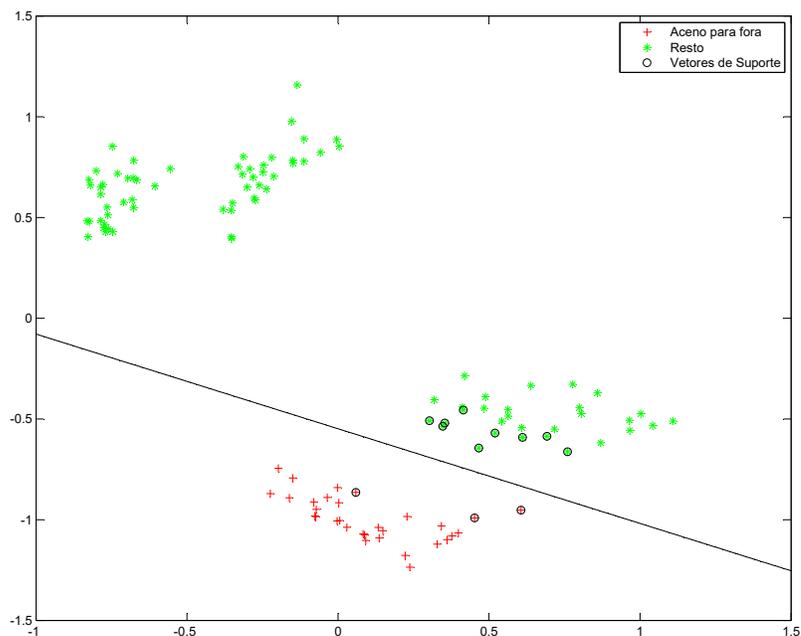


Figura 3.25: SVM do teste 2 - aceno para fora contra resto - 5 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.

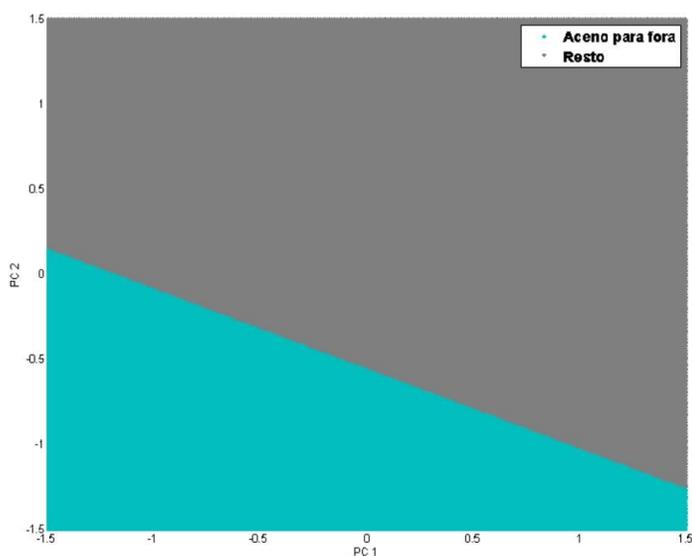


Figura 3.26: Região da SVM do teste 2 - aceno para fora contra resto - 5 gestos.

O terceiro classificador é o “aceno para dentro contra resto”. Um kernel do tipo gaussiano radial foi selecionado para este classificador. A Figura 3.27 mostra a SVM do teste 3 para 5 gestos em duas dimensões, a SVM utilizada para classificação considera todas as dimensões dos pontos. A Figura 3.28 mostra a região da SVM do teste 3 para 5 gestos.

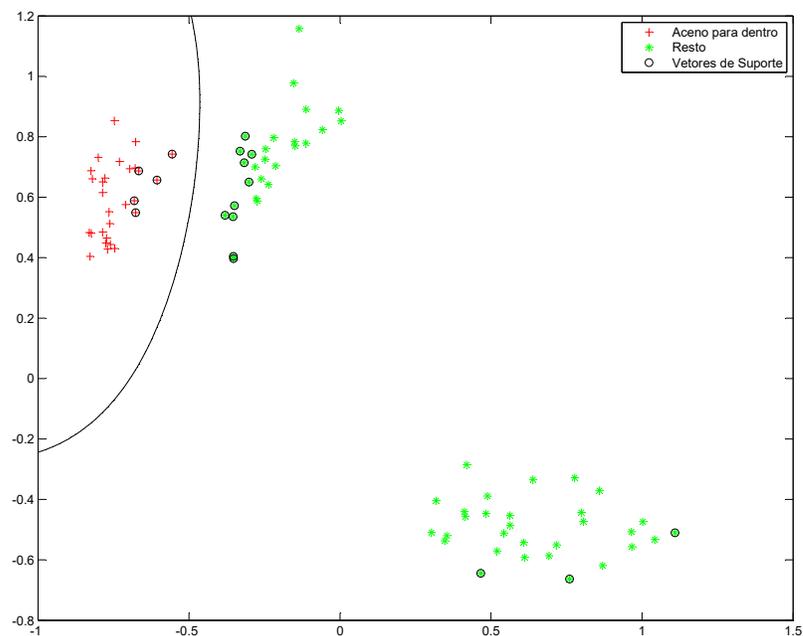


Figura 3.27: SVM do teste 3 - aceno para dentro contra resto - 5 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.

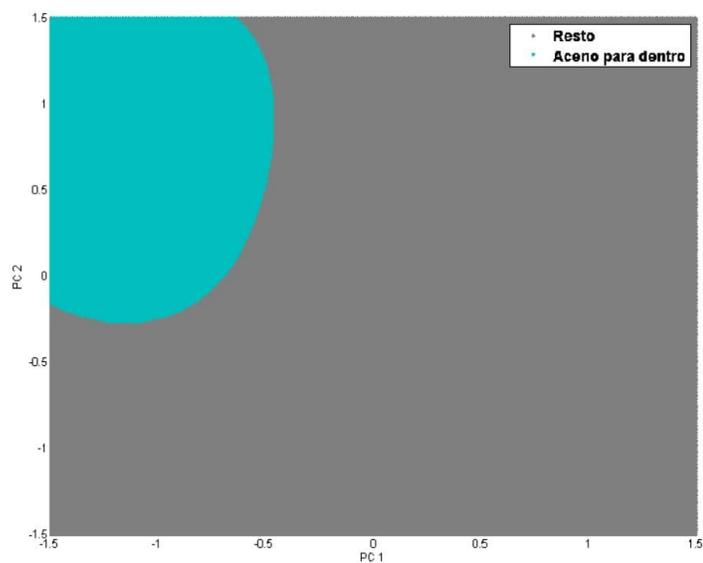


Figura 3.28: Região da SVM do teste 3 - aceno para dentro contra resto - 5 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.

O quarto classificador é o “punho fechado contra resto”. Um kernel do tipo linear foi selecionado para este classificador. A Figura 3.29 mostra a SVM do teste 4 para 5 gestos em duas dimensões, a SVM utilizada para classificação considera todas as dimensões dos pontos. A Figura 3.30 mostra a região da SVM do teste 4 para 5 gestos.

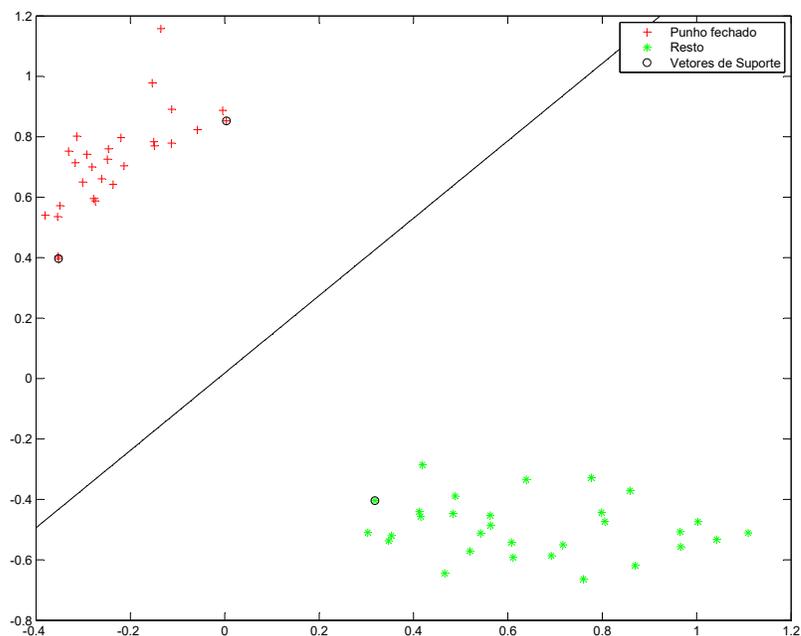


Figura 3.29: SVM do teste 4 - punho fechado contra resto - 5 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.

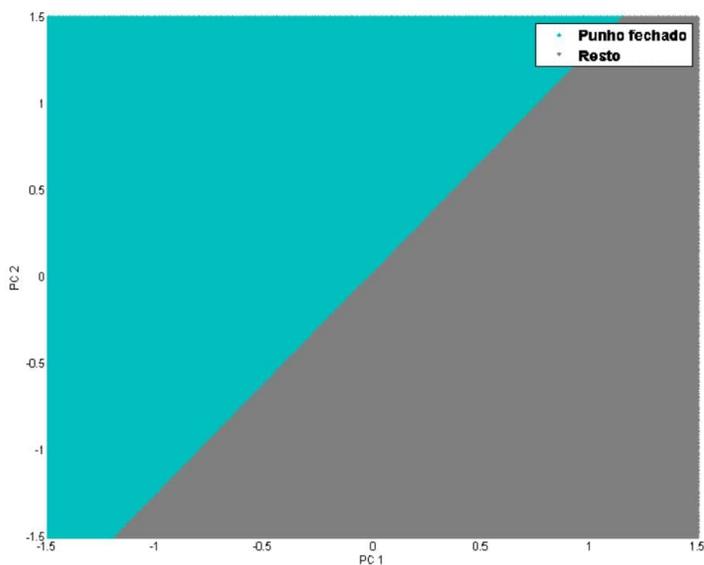


Figura 3.30: Região da SVM do teste 4 - punho fechado contra resto - 5 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.

### 3.9 CLASSIFICAÇÃO

O resultado da fase de treinamento é uma árvore do tipo MBT que implementa o classificador. Na fase de classificação os novos dados de sEMG devem ser assinalados a uma das classes que o sistema é capaz de reconhecer utilizando a árvore de classificação. Os novos dados são pré-processados, suas características extraídas e selecionadas utilizando a técnica de PCA da mesma forma que na fase de treinamento. Após a etapa de seleção de características os dados não clusterizados como na fase de treinamento, os pontos já estão prontos para serem classificados.

Com o objetivo de validar o classificador e verificar se os tipos de regiões com cada kernel personalizado atende com eficácia a classificação dos dados de entrada, um classificador em modo *online* operado por um único usuário é utilizado. O MYO obtém dados a aproximadamente 200Hz de frequência e os ciclos de análise são realizados a cada 500 milissegundos.

A condução de testes iniciais revela um ponto que deve ser considerado na classificação dos gestos utilizando SVMs. Ao realizar um gesto após outro, um “rastros” de dados pode ocorrer entre uma região de classificação de um movimento e outro, levando a erros de classificação. Por exemplo, ao conduzir um teste com a sequência de movimentos DESCANSO - ACENO PARA DENTRO - ACENO PARA FORA (TRIAL 001) o classificador identifica por alguns ciclos o movimento CHIFRE, pois a região de classificação deste movimento é intermediária, ou seja, está entre as regiões de classificação dos movimentos de origem e de destino. A Figura 3.31 mostra o resultado da classificação para o teste TRIAL 001 com os erros de classificação devido à passagem por regiões intermediárias das SVMs.

```
-----Inicializing CLASSIFIER ONLINE MODE-----
Cleaning left over mess...

Number of Myos detected: 1.
Arm: righth.
EMG reading rate: 51.11 Hz.
IMU reading rate: 201.01 Hz.
Starting EMG reading now for infinite cycles of 0.500000 sec:
Gesto - DESCANSO.
Gesto - ACENO PARA DENTRO.
Gesto - CHIFRE.
Gesto - CHIFRE.
Gesto - ACENO PARA FORA.
```

Figura 3.31: TRIAL 001 - Resultado com erro de classificação devido à passagem por regiões intermediárias.

Observe que no gráfico das regiões da SVM “descanso contra resto” mostrado na Figura 3.32 é visível o momento em que os pontos foram classificados de forma errônea devido ao rastro do movimento de um gesto para outro. Os círculos vermelhos indicam classificado como DESCANSO, os círculos em azul indicam classificado como RESTO. O círculo tracejado de cor preta evidencia os três pontos que formam o rastro originados pela transição de gestos, os quais eventualmente repousaram na região do gesto CHIFRE.

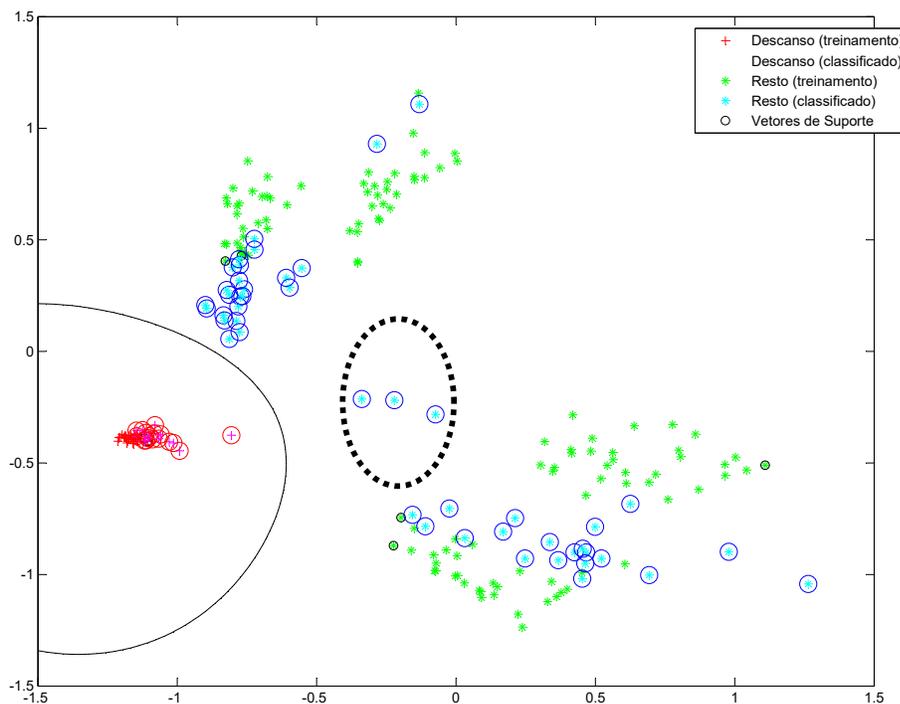


Figura 3.32: TRIAL 001 - Gráfico mostrando erro de classificação devido à passagem por regiões intermediárias. PC 1 no eixo horizontal e PC 2 no eixo vertical.

A solução encontrada para este problema foi adicionar um grau de histerese à identificação dos pontos a uma classe. Histerese é a tendência de um sistema manter seu estado mesmo na ausência do estímulo que causou mudança, como uma inércia para sair de um estado que foi posicionado por algum motivo. Mesmo que um novo estímulo que favoreça uma nova mudança de estado seja aplicado ao sistema, este leva um certo tempo para alterar seu estado. Partindo para aplicação deste conceito ao projeto em questão significa dizer que um novo gesto só pode ser considerado pelo reconhecedor de gestos quando este receber diversas entradas de dados e classificá-las seguidamente como um gesto diferente do atual estado do classificador.

O classificador foi validado pela condução de mais testes *online* com outros gestos e ajustado quando necessário, de forma que estivesse pronto para os testes com usuários diferentes. A Figura 3.33 mostra resultados de classificação do teste TRIAL 002 para a SVM “aceno para fora contra resto”. A Figura 3.34 mostra resultados de classificação do teste TRIAL 003 para a SVM “aceno para dentro contra resto”. A Figura 3.35 mostra resultados de classificação do teste TRIAL 004 para a SVM “punho fechado contra resto”.

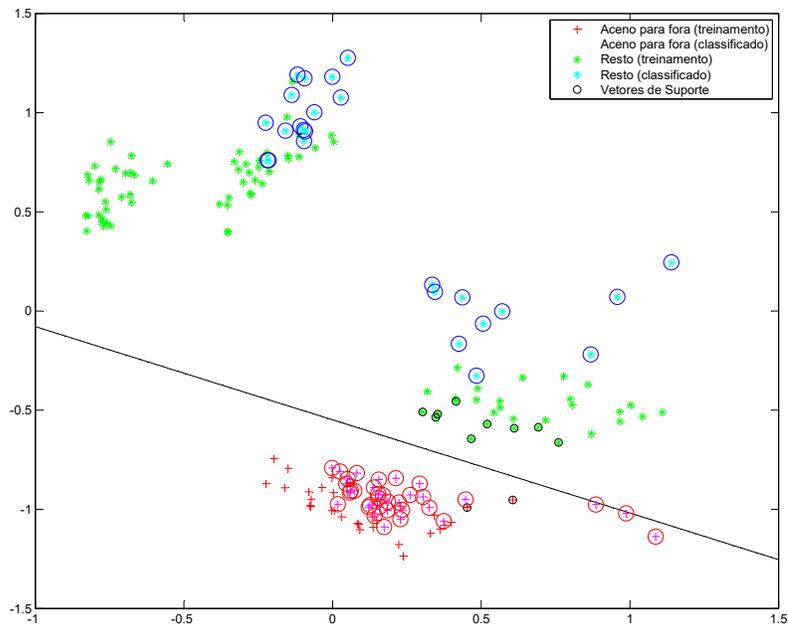


Figura 3.33: TRIAL 002 - Gráfico com resultados do teste aceno para fora contra resto. PC 1 no eixo horizontal e PC 2 no eixo vertical.

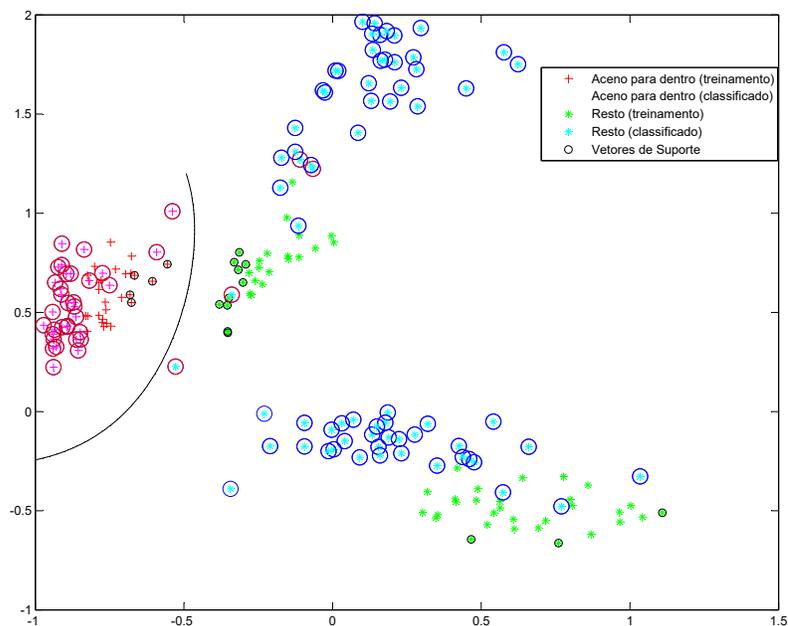


Figura 3.34: TRIAL 003 - Gráfico com resultados do teste aceno para dentro contra resto. PC 1 no eixo horizontal e PC 2 no eixo vertical.

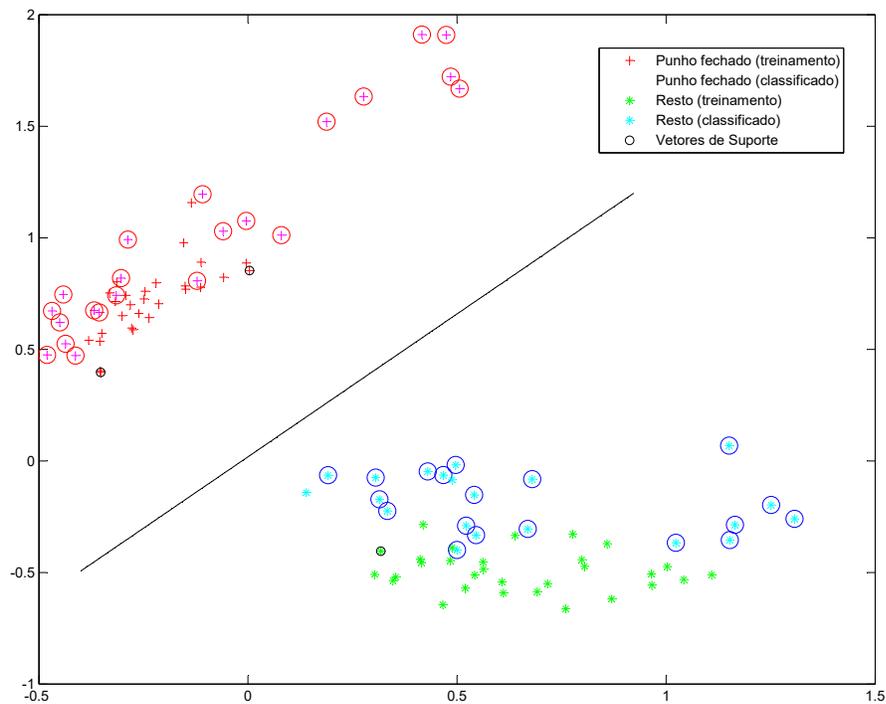


Figura 3.35: TRIAL 004 - Gráfico com resultados do teste punho fechado contra resto. PC 1 no eixo horizontal e PC 2 no eixo vertical.

### 3.10 CONCLUSÃO

Neste capítulo são desenvolvidas as fases de treinamento e classificação de nove gestos de mão, passando por todas as etapas de cada fase. Dois tipos de testes foram utilizados para fins de exemplificação, um teste com 5 gestos (descanso, punho fechado, aceno para fora, aceno para dentro e chifre) e outro teste com todos os 9 gestos. Um modelo de teste *online* é utilizado para validação do classificador que foi desenvolvido, bem como para ajustar os parâmetros de clusterização.

Outras ferramentas auxiliares colaboram na validação do projeto, tais como histogramas, gráficos dos pontos projetados em duas e três dimensões espaciais para visualização, e gráfico de contribuição percentual. No próximo capítulo será mostrado os testes de desempenho do classificador.

# 4

## TESTES DE DESEMPENHO

---

Neste capítulo são apresentados os testes conduzidos para fins de análise de desempenho do classificador. A metodologia de testes é proposta na primeira sessão. Em seguida é apresentado um compilado dos resultados dos testes.

### 4.1 METODOLOGIA

Para a realização dos testes de desempenho, os gestos são identificados em tempo real. Os testes foram conduzidos com um grupo de 5 pessoas, sendo 3 homens e 2 mulheres, aqui chamados de sujeitos. Os sujeitos realizam os testes sentados. Após serem instruídos sobre o gestos que o sistema reconhece e se habituarem com o Myo, inicia-se a aplicação para testes, a qual indica para o sujeito qual gesto deve ser feito e em que momento. Os sujeitos devem executar os gestos na ordem em que são indicados e pelo tempo requerido. Cada teste consiste em realizar cada um dos gestos em teste por 5 segundos seguidos, e então o gesto indicado é alterado. Por fim, a aplicação gera um relatório com a taxa de acertos para cada gesto.

Para fins de simplicidades, os gestos recebem siglas, sejam elas: descanso - D; punho fechado - P; aceno para fora - AF; aceno para dentro - AD; mão espalmada - E; chifre - C; hang loose - HL; arma - A; legal - L. As sequências de gestos são:

1. Teste com 5 gestos. Os gestos reconhecidos são D, P, AF, AD e C. As sequências dos gestos de cada teste são:
  - (a) Teste tipo 5-1: D - P - D.
  - (b) Teste tipo 5-2: D - P - AF - AD - C.
  - (c) Teste tipo 5-3: D - P - AF - AD - C - AD - AF - P - D.
2. Teste com 9 gestos. Os gestos reconhecidos são D, P, AF, AD, E, C, HL, A e L. As sequências dos gestos de cada teste são:
  - (a) Teste tipo 9-1: D - P - AF - AD - C - AD - AF - P - D.
  - (b) Teste tipo 9-2: D - P - AF - AD - E - C - HL - A - L.

### 4.2 RESULTADOS

Foram realizados os cinco tipos de testes com cada um dos sujeitos voluntários, os resultados estão sumarizados nas tabelas 4.1, 4.2, 4.3, 4.4 e 4.5.

Teste	D	P	AF	AD	E	C	HL	A	L	Média
5-1	100%	100%	N/A	N/A	N/A	N/A	N/A	N/A	N/A	100%
5-2	100%	100%	100%	100%	N/A	100%	N/A	N/A	N/A	100%
5-3	100%	100%	100%	100%	N/A	100%	N/A	N/A	N/A	100%
9-1	100%	33,33%	100%	45,45%	N/A	0%	N/A	N/A	N/A	67,61%
9-2	100%	33,33%	100%	66,67%	66,67%	0%	0%	0%	100%	56,25%

Tabela 4.1: Resultados dos testes do sujeito 1 - sexo masculino, 25 anos.

Teste	D	P	AF	AD	E	C	HL	A	L	Média
5-1	100%	100%	N/A	N/A	N/A	N/A	N/A	N/A	N/A	100%
5-2	100%	100%	87,50%	0%	N/A	100%	N/A	N/A	N/A	69,77%
5-3	100%	100%	30%	0%	N/A	100%	N/A	N/A	N/A	63,08%
9-1	100%	0%	36,37%	16,67%	N/A	0%	N/A	N/A	N/A	40,91%
9-2	100%	50%	100%	16,67%	16,67%	0%	0%	0%	100%	52,78%

Tabela 4.2: Resultados dos testes do sujeito 2 - sexo masculino, 54 anos.

Teste	D	P	AF	AD	E	C	HL	A	L	Média
5-1	100%	100%	N/A	N/A	N/A	N/A	N/A	N/A	N/A	100%
5-2	100%	100%	0%	75%	N/A	100%	N/A	N/A	N/A	74,36%
5-3	100%	100%	0%	58,33%	N/A	100%	N/A	N/A	N/A	69,74%
9-1	100%	0%	0%	0%	N/A	0%	N/A	N/A	N/A	31,15%
9-2	100%	0%	83,33%	0%	0%	0%	40%	0%	100%	40,91%

Tabela 4.3: Resultados dos testes do sujeito 3 - sexo feminino, 24 anos.

Teste	D	P	AF	AD	E	C	HL	A	L	Média
5-1	100%	100%	N/A	N/A	N/A	N/A	N/A	N/A	N/A	100%
5-2	100%	25%	85,71%	0%	N/A	100%	N/A	N/A	N/A	65,85%
5-3	100%	41,67%	100%	0%	N/A	100%	N/A	N/A	N/A	70,77%
9-1	100%	0%	100%	0%	N/A	0%	N/A	N/A	N/A	50%
9-2	100%	0%	100%	0%	0%	0%	0%	0%	12,50%	28,77%

Tabela 4.4: Resultados dos testes do sujeito 4 - sexo feminino, 50 anos.

Teste	D	P	AF	AD	E	C	HL	A	L	Média
5-1	100%	100%	N/A	N/A	N/A	N/A	N/A	N/A	N/A	100%
5-2	100%	100%	100%	100%	N/A	75%	N/A	N/A	N/A	95,24%
5-3	100%	100%	25%	88,26%	N/A	100%	N/A	N/A	N/A	85,71%
9-1	100%	0%	100%	0%	N/A	0%	N/A	N/A	N/A	50%
9-2	100%	0%	100%	0%	33,33%	0%	0%	0%	100%	40,79%

Tabela 4.5: Resultados dos testes do sujeito 5 - sexo masculino, 23 anos.

Os resultados práticos final dos testes, que consistem na média aritmética dos resultados parciais para cada gesto, estão sumarizados na Tabela 4.6.

Gestos	D	P	AF	AD	E	C	HL	A	L	Média
5	100%	91%	63%	52%	N/A	98%	N/A	N/A	N/A	81%
9	100%	12%	82%	15%	23%	0%	8%	0%	83%	46%

Tabela 4.6: Resultados finais.

Portanto, os testes para 5 gestos mostram que o reconhecedor de 5 gestos possui taxa de acertos média em tempo real de 81%, demonstrando que pode ser utilizado em interfaces complexas e avaliação de movimentos para reabilitação fisioterapêutica. Já os testes para 9 gestos demonstram baixa taxa média de acertos, 46%. Isso deve ao fato de que os gestos inseridos no reconhecedor de 9 gestos apresentam dados de sEMG muito similares a outros gestos, dificultando muito o treinamento e a classificação.

Os maiores desafios para os dois tipos de reconhecedor de gestos foi em relação ao posicionamento do MYO, pois algumas características dos sujeitos variam muito, como a espessura do antebraço, quantidade de pelos e gordura e desenvolvimento muscular. De fato, para cada sujeito foi preciso realizar alterações no posicionamento para encontrar o melhor resultado. Alguns grampos são utilizados para ajuste de tamanho do antebraço no MYO, mas os sensores nem sempre ficam posicionados na mesma região, ou seja, sobre os mesmos músculos ao se considerar dois sujeitos com espessuras de antebraço muito diferentes. É possível notar também que os sujeitos se adaptam aos gestos, de forma que foi preciso um tempo de ambientação em que os sujeitos pudessem observar os resultados que o reconhecedor atribui para cada gesto a fim de realizar os gestos da maneira apropriada.

Em relação ao reconhecedor de 9 gestos, percebeu-se grande dificuldade ao tentar separar os gestos com dados similares, pois a técnica de SVM se mostrou muito sensível e incapaz de diferenciar alguns gestos cuja análise resulta em pontos que geram regiões muito próximas no gráfico de pontos projetados sobre as componentes principais.

Este capítulo cumpre o objetivo de sumarizar tudo o que foi concluído com o desenvolvimento deste projeto, bem como propor trabalhos futuros para prosseguimento deste projeto.

## 5.1 CONSIDERAÇÕES FINAIS

Esta dissertação apresenta o estudo e desenvolvimento de um sistema reconhecedor de gestos de mão utilizando dados de Eletromiografia de superfície do antebraço. Os objetivos específicos deste trabalho estão sumarizados como aplicar técnicas conhecidas de processamento e análise de dados com o objetivo de classificar dados de sEMG e criar uma interface que utilize o reconhecimento de gestos para executar alguma tarefa de interesse para o usuário. Um estudo preliminar da literatura que versa sobre o uso de tecnologias vestíveis e seu uso para o campo de cuidados para a saúde (*healthcare*) e reabilitação são expostos. Técnicas para tratamento, análise, clusterização, treinamento e classificação de dados são apresentadas como ferramentas para solucionar o problema proposto.

Uma abordagem de aplicação das técnicas de extração de features, bem como a seleção por PCA é desenvolvida no andamento deste trabalho. O foco desta dissertação se caracteriza por um algoritmo inovador para clusterização, treinamento e classificação que utiliza ferramentas comuns para tais fins, como *K-means* para clusterização, SVM para treinamento e classificação binária e MBT para classificação binária estendida para multi classe, mas com rotinas específicas que tornam o processo mais ágil e eficiente.

Uma metodologia de testes foi proposta para 5 e 9 gestos, sendo que o reconhecedor de 5 gestos possui taxa de acertos média em tempo real de 81%. Já os testes para 9 gestos demonstram taxa média de acertos de 46%. Assim como os trabalhos discutidos na sessão 2.3, este trabalho apresenta melhores resultados quando configurado em regime mais restritivo, no caso menos gestos no conjunto de classificação. O reconhecedor para 5 gestos apresenta resultado compatível com os trabalhos mais recentes na área de reconhecimento de gestos de membro superior, com taxa média de acerto maior que 80%. Entretanto, este trabalho contribui aos estudos do campo abordado com o desenvolvimento de uma metodologia na qual nenhuma configuração ou calibração prévia ao uso é necessária, através de um dispositivo leve e que independe do ambiente de uso.

Uma interface visual simples para classificação online foi desenvolvida. Através desta interface os resultados são exibidos e podem ser utilizados para múltiplos fins. Os resultados da classificação se tornam disponíveis e poderiam ser integrados sem muitos desafios a plataformas desenvolvidas com tecnologias do MatLab ou C++.

Portanto, os objetivos propostos são alcançados, os problemas encontrados durante o desenvolvimento são expostos e soluções são propostas para a solução destas. O reconhecedor de 5 gestos utilizando as técnicas propostas se mostrou eficiente para uso online, enquanto o reconhecedor de 9 gestos não foi considerado um bom instrumento para o fim que foi projetado devido aos resultados já mencionados.

## 5.2 TRABALHOS FUTUROS

Os próximos passos de desenvolvimento para dar seguimento a este trabalho se iniciam com melhorias no classificador para que este seja capaz de identificar mais gestos de forma eficiente, buscando novas maneiras de diferenciar gestos cujas features sejam muito semelhantes, seja com o acréscimo de mais sensores ou com técnicas mais sensíveis de treinamento e classificação.

Os dados dos sensores inerciais podem ser combinados com os dados de sEMG para uma análise combinada de gestos ou mesmo movimentos dos membros superiores. Como mostrado no capítulo anterior, alguns gestos apresentam características muito semelhantes, dificultando a diferenciação entre eles. Desta forma, a fusão de sensores pode proporcionar mais precisão na classificação destes gestos.

Utilizando os resultados do reconhecedor de gestos proposto neste trabalho, pode-se desenvolver a integração com interfaces inteligentes para pessoas com pouca mobilidade controlarem dispositivos ubíquos, bem como com dispositivos de FES para estimulação de membro parético em pacientes em reabilitação.

Outro ponto a ser abordado é o uso da interface por gestos para controlar algum sistema externo, seja um software que integre o reconhecedor de gestos ou mesmo enviar comandos para outras plataformas com hardware próprio, preferencialmente para fins que auxiliem pessoas em processo de reabilitação ou com movimentos limitados devido a traumas.

## BIBLIOGRAFIA

---

- [1] U. Varshney, "Pervasive healthcare," *Computer*, vol. 36, no. 12, pp. 138–140, dec 2003.
- [2] M. M. Baig, H. GholamHosseini, and M. J. Connolly, "Integrated vital signs monitoring system using ubiquitous devices: Multiple physical signs detection and decision support for hospitalized older adults," in *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. Institute of Electrical and Electronics Engineers (IEEE), aug 2015.
- [3] J. A. Judith Symonds and D. Parry, *Auto-Identification and Ubiquitous Computing Applications: RFID and Smart Technologies for Information Convergence*, K. Klinger, Ed. IGI Global, 2009.
- [4] T. Barger, D. Brown, and M. Alwan, "Health-status monitoring through analysis of behavioral patterns," *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, vol. 35, no. 1, pp. 22–27, jan 2005.
- [5] D. Wilson and C. Atkeson, "Simultaneous tracking & activity recognition (star) using many anonymous, binary sensors," 2005.
- [6] V. K. Kelly Barnes and C. Connolly, "Pwc hri wearable devices," PwCâs Health Research Institute - PricewaterhouseCoopers, Tech. Rep., 2014.
- [7] S. M. Waller and J. Whittall, "Bilateral arm training: Why and who benefits?" *NeuroRehabilitation*, vol. 23, no. 1, pp. 29–41, Mar. 2008.
- [8] A. E. Q. van Delden, C. E. Peper, and Others, "Unilateral versus bilateral upper limb exercise therapy after stroke: a systematic review." *J Rehabil Med*, vol. 44, no. 2, pp. 106–117, Feb. 2012.
- [9] J. H. Cauraugh, N. Lodha, and Others, "Bilateral movement training and stroke motor recovery progress: A structured review and meta-analysis," *Human Movement Science*, vol. 29, no. 5, pp. 853–870, Oct. 2010.
- [10] J. H. Cauraugh and S. Kim, "Two coupled motor recovery protocols are better than one: electromyogram-triggered neuromuscular stimulation and bilateral movements," *Stroke*, vol. 33, no. 6, pp. 1589–1594, Jun. 2002.
- [11] J. S. Knutson, M. Y. Harley, T. Z. Hisel, S. D. Hogan, M. M. Maloney, and J. Chae, "Contralaterally controlled functional electrical stimulation for upper extremity hemiplegia," *Neurorehabilitation and Neural Repair*, vol. 26, no. 3, pp. 239–246, aug 2011. [Online]. Available: <https://doi.org/10.1177/1545968311419301>
- [12] C. H. Jang, H. S. Yang, H. E. Yang, S. Y. Lee, J. W. Kwon, B. D. Yun, J. Y. Choi, S. N. Kim, and H. W. Jeong, "A survey on activities of daily living and occupations of upper extremity amputees," *Annals of Rehabilitation Medicine*, vol. 35, no. 6, p. 907, 2011. [Online]. Available: <https://doi.org/10.5535/arm.2011.35.6.907>
- [13] K. Englehart and B. Hudgins, "A robust, real-time control scheme for multifunction myoelectric control," *IEEE Transactions on Biomedical Engineering*, vol. 50, no. 7, pp. 848–854, jul 2003. [Online]. Available: <https://doi.org/10.1109/tbme.2003.813539>

- [14] Y. Zhang, J. Nieveen *et al.*, “Individual hand movement detection and classification using peripheral nerve signals,” in *IEEE EMBS Conference on Neural Engineering*, May 2017.
- [15] P. Geethanjali, “Comparative study of pca in classification of multichannel emg signals,” *Australasian Physical & Engineering Sciences in Medicine*, vol. 38, no. 2, pp. 331–343, Jun 2015. [Online]. Available: <https://doi.org/10.1007/s13246-015-0343-8>
- [16] N. F. Güler and S. Koçer, “Classification of emg signals using pca and fft,” *Journal of Medical Systems*, vol. 29, no. 3, pp. 241–250, Jun 2005. [Online]. Available: <https://doi.org/10.1007/s10916-005-5184-7>
- [17] S. Sudarsan and E. C. Sekaran, “Design and development of EMG controlled prosthetics limb,” *Procedia Engineering*, vol. 38, pp. 3547–3551, 2012.
- [18] P. Parker, K. Englehart, and B. Hudgins, “Myoelectric signal processing for control of powered limb prostheses,” *Journal of Electromyography and Kinesiology*, vol. 16, no. 6, pp. 541–548, dec 2006.
- [19] J. Lobo-Prat, A. Q. Keemink, A. H. Stienen, A. C. Schouten, P. H. Veltink, and B. H. Koopman, “Evaluation of EMG, force and joystick as control interfaces for active arm supports,” *Journal of NeuroEngineering and Rehabilitation*, vol. 11, no. 1, p. 68, 2014.
- [20] T. A. Kuiken, “Targeted muscle reinnervation for real-time myoelectric control of multifunction artificial arms,” *JAMA*, vol. 301, no. 6, p. 619, feb 2009.
- [21] V. Maheu, J. Frappier, P. S. Archambault, and F. Routhier, “Evaluation of the JACO robotic arm: Clinico-economic study for powered wheelchair users with upper-extremity disabilities,” in *2011 IEEE International Conference on Rehabilitation Robotics*. IEEE, jun 2011.
- [22] H. S. Lo and S. Q. Xie, “Exoskeleton robots for upper-limb rehabilitation: State of the art and future prospects,” *Medical Engineering & Physics*, vol. 34, no. 3, pp. 261–268, apr 2012.
- [23] S. Sharma and A. K. Dubey, “Movement control of robot in real time using EMG signal,” in *2012 2nd International Conference on Power, Control and Embedded Systems*. IEEE, dec 2012.
- [24] K. Abbruzzese, D. Lee, A. Swedberg, H. Talasan, and M. Paliwal, “An innovative design for an assistive arm orthosis for stroke and muscle dystrophy,” in *2011 IEEE 37th Annual Northeast Bioengineering Conference (NEBEC)*. IEEE, apr 2011.
- [25] R. Jiménez-Fabián and O. Verlinden, “Review of control algorithms for robotic ankle systems in lower-limb orthoses, prostheses, and exoskeletons,” *Medical Engineering & Physics*, vol. 34, no. 4, pp. 397–408, may 2012.
- [26] J. C. Perry, J. Rosen, and S. Burns, “Upper-limb powered exoskeleton design,” *IEEE/ASME Transactions on Mechatronics*, vol. 12, no. 4, pp. 408–417, aug 2007.
- [27] D. J. McFarland and J. R. Wolpaw, “Brain-computer interfaces for communication and control,” *Communications of the ACM*, vol. 54, no. 5, p. 60, may 2011.
- [28] A. E. Schultz and T. A. Kuiken, “Neural interfaces for control of upper limb prostheses: The state of the art and future possibilities,” *PM&R*, vol. 3, no. 1, pp. 55–67, jan 2011.
- [29] O. M. da Saude, “Site da organizacao mundial da saude,” [www.who.int/topics/rehabilitation/en/](http://www.who.int/topics/rehabilitation/en/).

- [30] K. Huang, “Exploring in-home monitoring of rehabilitation and creating an authoring tool for physical therapists,” phdthesis, Carnegie Mellon University, Dec. 2015, <http://repository.cmu.edu/dissertations/668>.
- [31] A. L. Coffey, “Ubiquitous and wearable computing solutions for enhancing motor rehabilitation of the upper extremity post-stroke,” Ph.D. dissertation, National University of Ireland Maynooth, 2016.
- [32] M. Chan and R. B. Zoellick, “World report on disability,” Organizacao Mundial da Saude, Tech. Rep., 2011.
- [33] V. Lopez-Jaquero and F. Montero, “Specifying how to motivate people in computer assisted rehabilitation,” in *Ubiquitous Computing and Ambient Intelligence*. Springer International Publishing, 2016, pp. 99–110.
- [34] B. P. Jarochowski, S. Shin, D. Ryu, and H. Kim, “Ubiquitous rehabilitation center: An implementation of a wireless sensor network based rehabilitation management system,” in *2007 International Conference on Convergence Information Technology (ICCIT 2007)*. IEEE, nov 2007.
- [35] S. Mitra and T. Acharya, “Gesture recognition: A survey,” *IEEE Transactions on Systems, Man and Cybernetics, Part C (Applications and Reviews)*, vol. 37, no. 3, pp. 311–324, may 2007.
- [36] M. Georgi, C. Amma, and T. Schultz, “Recognizing hand and finger gestures with IMU based motion and EMG based muscle activity sensing,” in *Proceedings of the International Conference on Bio-inspired Systems and Signal Processing*. SCITEPRESS - Science and Technology Publications, 2015.
- [37] F. Riillo, L. Quitadamo, F. Cavrini, E. Gruppioni, C. Pinto, N. C. Pastò, L. Sbernini, L. Albero, and G. Saggio, “Optimization of EMG-based hand gesture recognition: Supervised vs. unsupervised data preprocessing on healthy subjects and transradial amputees,” *Biomedical Signal Processing and Control*, vol. 14, pp. 117–125, nov 2014.
- [38] X. Zhang, X. Chen, Y. Li, V. Lantz, K. Wang, and J. Yang, “A framework for hand gesture recognition based on accelerometer and EMG sensors,” *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, vol. 41, no. 6, pp. 1064–1076, nov 2011.
- [39] J. Kim, S. Mastnik, and E. André, “EMG-based hand gesture recognition for realtime biosignal interfacing,” in *Proceedings of the 13th international conference on Intelligent user interfaces - IUI 08*. ACM Press, 2008.
- [40] A. Rahimi, S. Benatti, P. Kanerva, L. Benini, and J. M. Rabaey, “Hyperdimensional biosignal processing: A case study for EMG-based hand gesture recognition,” in *2016 IEEE International Conference on Rebooting Computing (ICRC)*. IEEE, oct 2016.
- [41] T. Shanableh, K. Assaleh, and M. Al-Rousan, “Spatio-temporal feature-extraction techniques for isolated gesture recognition in arabic sign language,” *IEEE Transactions on Systems, Man and Cybernetics, Part B (Cybernetics)*, vol. 37, no. 3, pp. 641–650, jun 2007.
- [42] G. Acampora, D. J. Cook, P. Rashidi, and A. V. Vasilakos, “A survey on ambient intelligence in health-care,” *Proceedings of the IEEE*, vol. 101, no. 12, pp. 2470–2494, dec 2013.
- [43] C. Freeman, “Feature selection and hierarchical classifier design with applications to human motion recognition,” Ph.D. dissertation, University of Waterloo, 2014.

- [44] J. Brownlee, “Supervised and unsupervised machine learning algorithms,” Website, Mar. 2016, <http://machinelearningmastery.com/supervised-and-unsupervised-machine-learning-algorithms/>.
- [45] M. Mahajan, P. Nimbhorkar, and K. Varadarajan, “The planar k-means problem is np-hard,” 2009.
- [46] S. Lloyd, “Least squares quantization in PCM,” *IEEE Transactions on Information Theory*, vol. 28, no. 2, pp. 129–137, mar 1982.
- [47] R. Ostrovsky, Y. Rabani, L. J. Schulman, and C. Swamy, “The effectiveness of lloyd-type methods for the k-means problem,” in *In 47th IEEE Symposium on the Foundations of Computer Science (FOCS, 2006*, pp. 165–176.
- [48] D. Arthur and S. Vassilvitskii, “K-means++: the advantages of careful seeding,” in *In Proceedings of the 18th Annual ACM-SIAM Symposium on Discrete Algorithms*, 2007.
- [49] S. Cheong, S. H. Oh, , and S.-Y. Lee, “Support vector machines with binary tree architecture for multi-class classification,” in *Neural Information Processing*, 2004, vol. 2, no. 3, pp. 47–51.
- [50] R. Rifkin and A. Klautau, “In defense of one-vs-all classification,” *J. Mach. Learn. Res.*, vol. 5, pp. 101–141, Dec. 2004.
- [51] D. J. Bora and A. K. Gupta, “Effect of different distance measures on the performance of k-means algorithm: An experimental study in matlab,” *International Journal of Computer Science and Information Technologies*, vol. 5, pp. 2501–2506, 2014.

# APÊNDICE

# A SVMs PARA 9 GESTOS

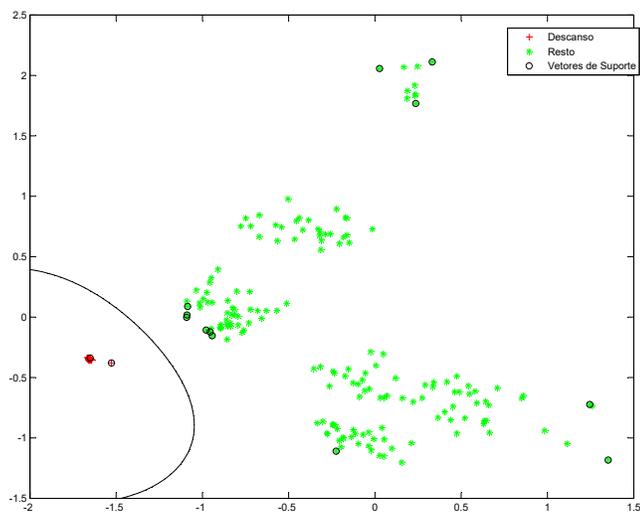


Figura A.1: SVM do teste 1 - descanso contra resto - 9 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.

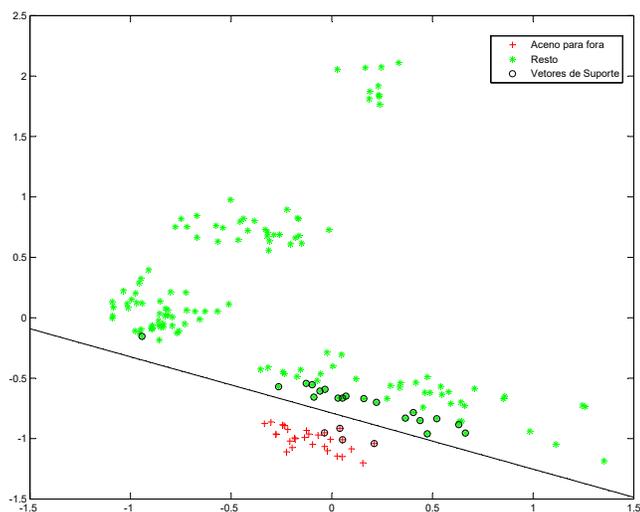


Figura A.2: SVM do teste 2 - aceno para fora contra resto - 9 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.

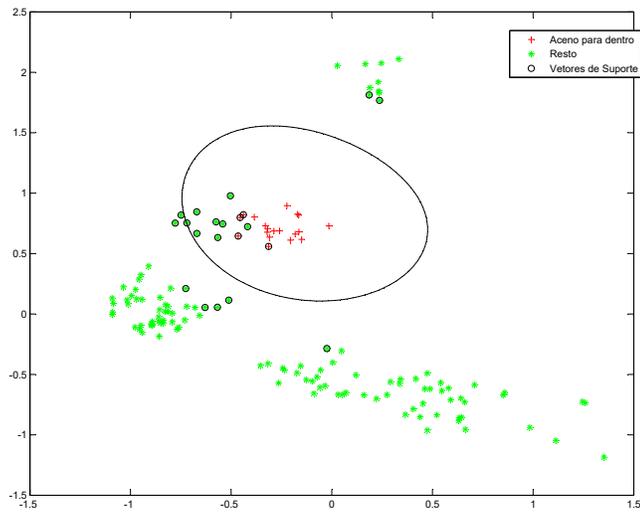


Figura A.3: SVM do teste 3 - aceno para dentro contra resto - 9 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.

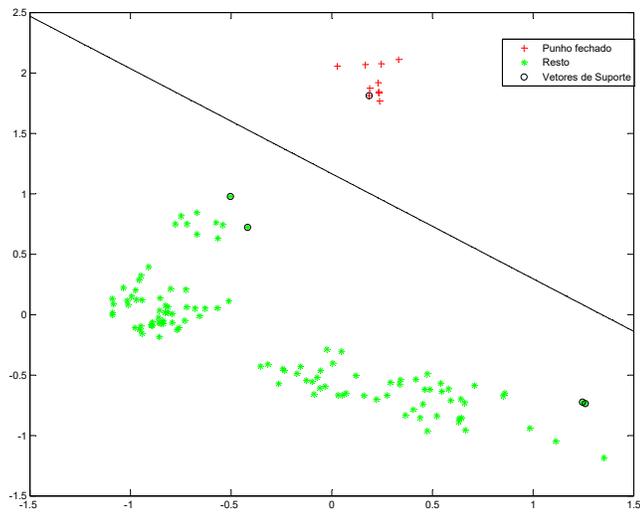


Figura A.4: SVM do teste 4 - punho fechado contra resto - 9 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.

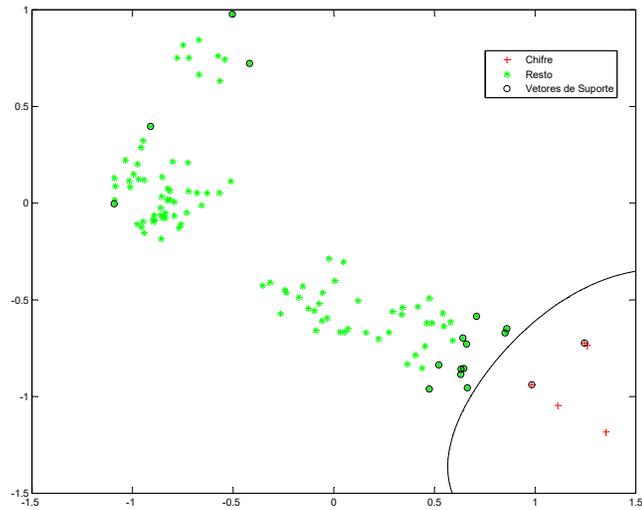


Figura A.5: SVM do teste 5 - chifre contra resto - 9 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.

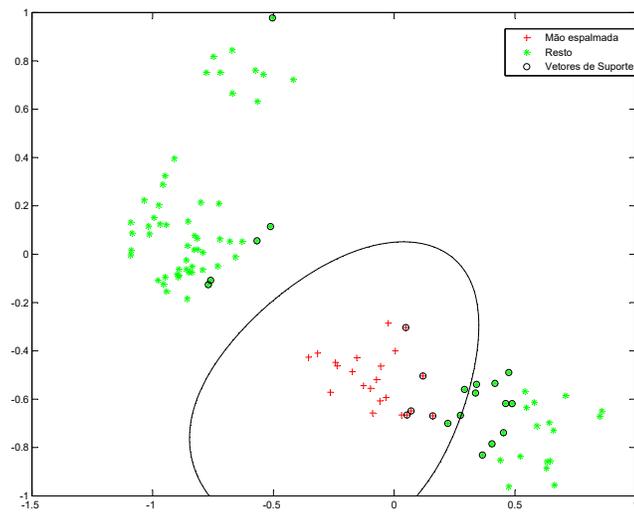


Figura A.6: SVM do teste 6 - mão espalmada contra resto - 9 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.

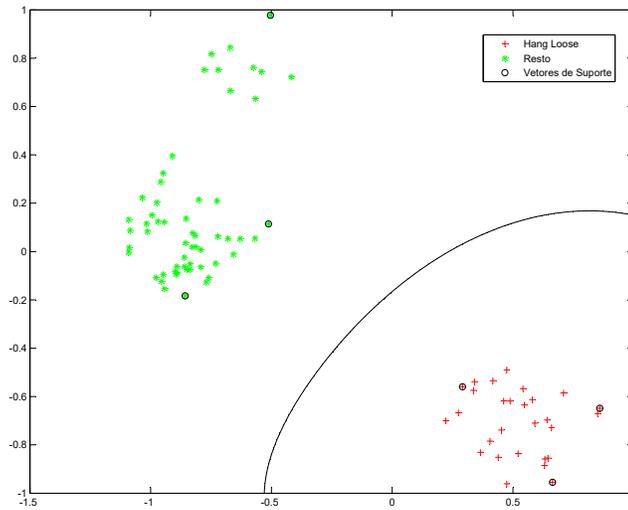


Figura A.7: SVM do teste 7 - hang loose contra resto - 9 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.

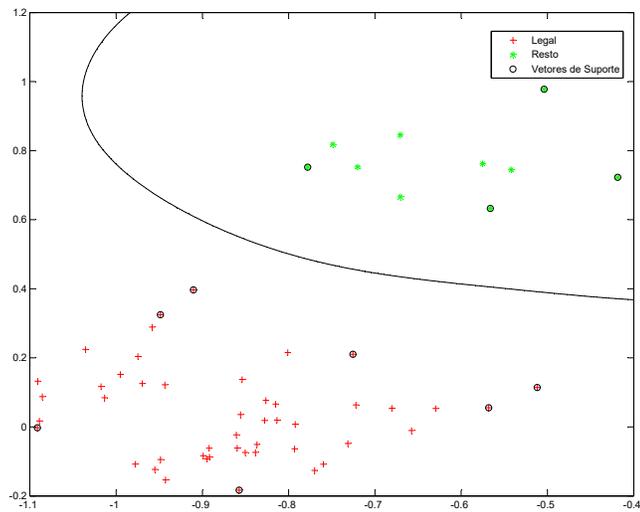


Figura A.8: SVM do teste 8 - legal contra resto - 9 gestos. PC 1 no eixo horizontal e PC 2 no eixo vertical.

# B FEATURES PARA 5 GESTOS

---

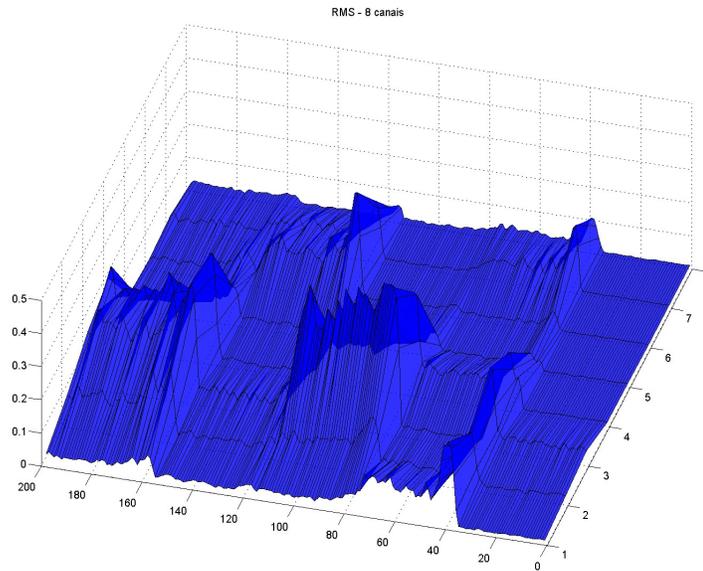


Figura B.1: RMS - 8 canais - 5 gestos.

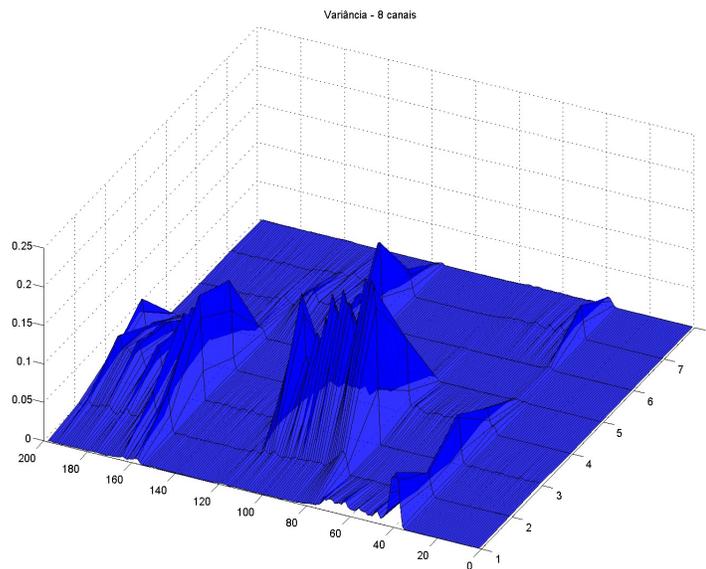


Figura B.2: Variância - 8 canais - 5 gestos.

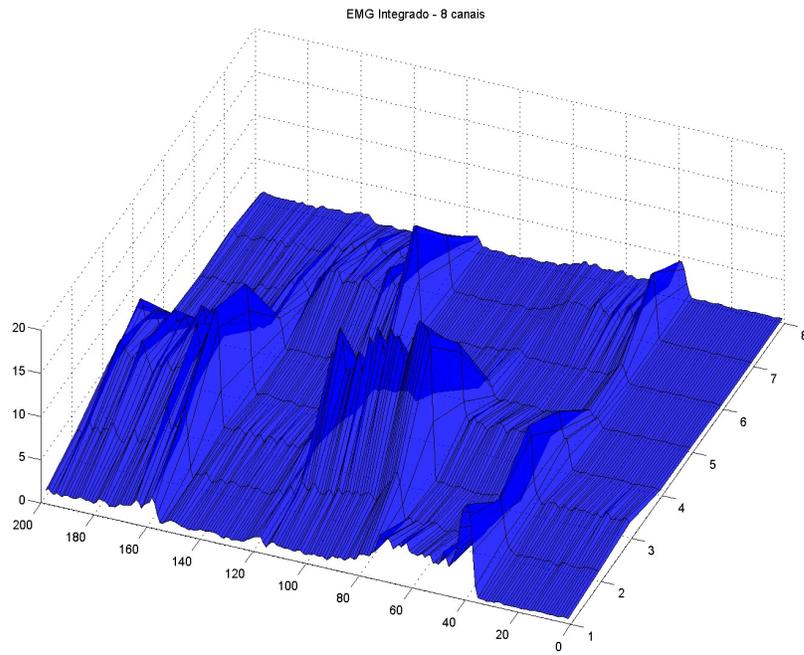


Figura B.3: EMG Integrado - 8 canais - 5 gestos.

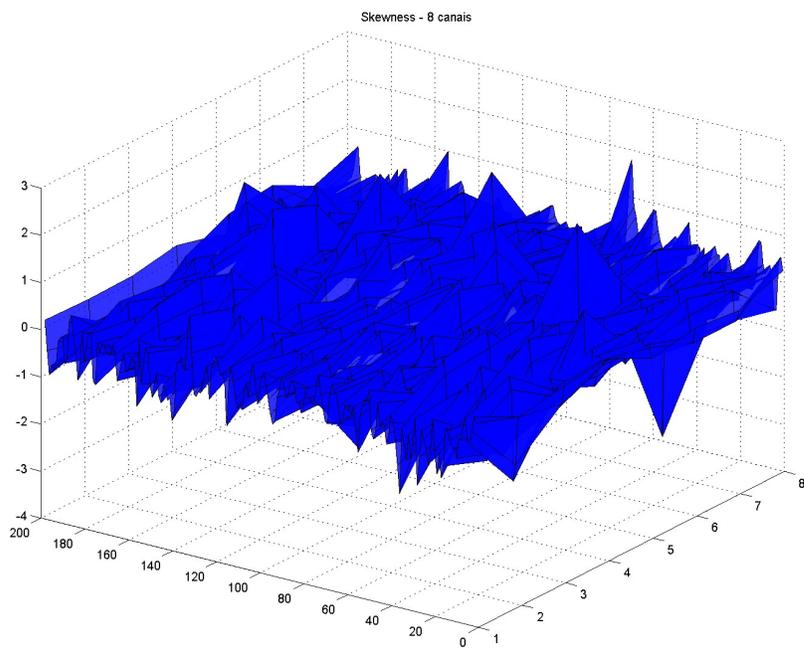


Figura B.4: Skewness - 8 canais - 5 gestos.

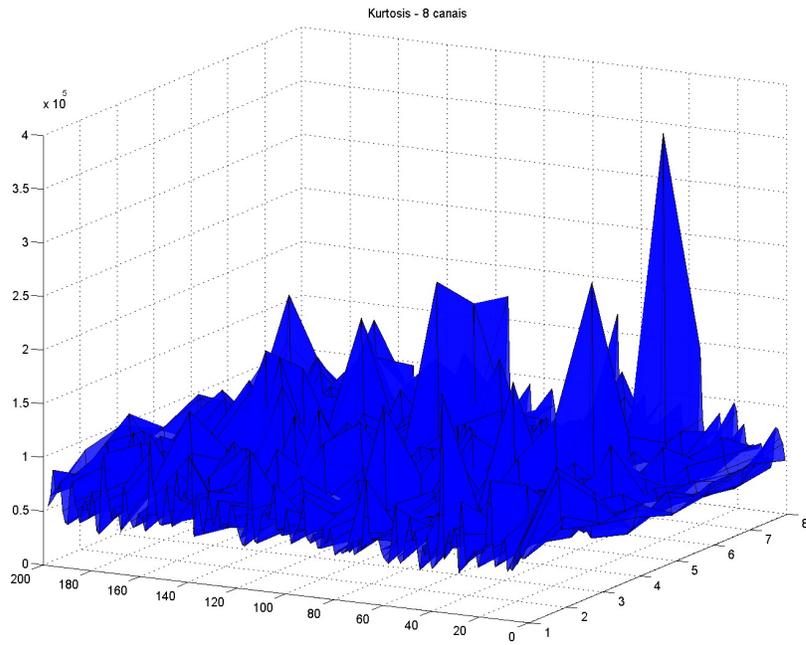


Figura B.5: Kurtosis - 8 canais - 5 gestos.

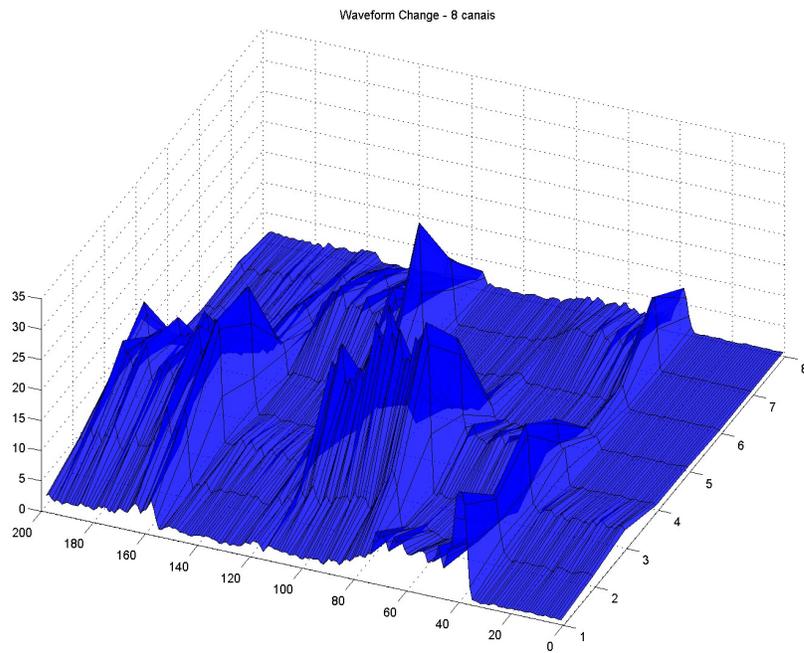


Figura B.6: Waveform Change - 8 canais - 5 gestos.

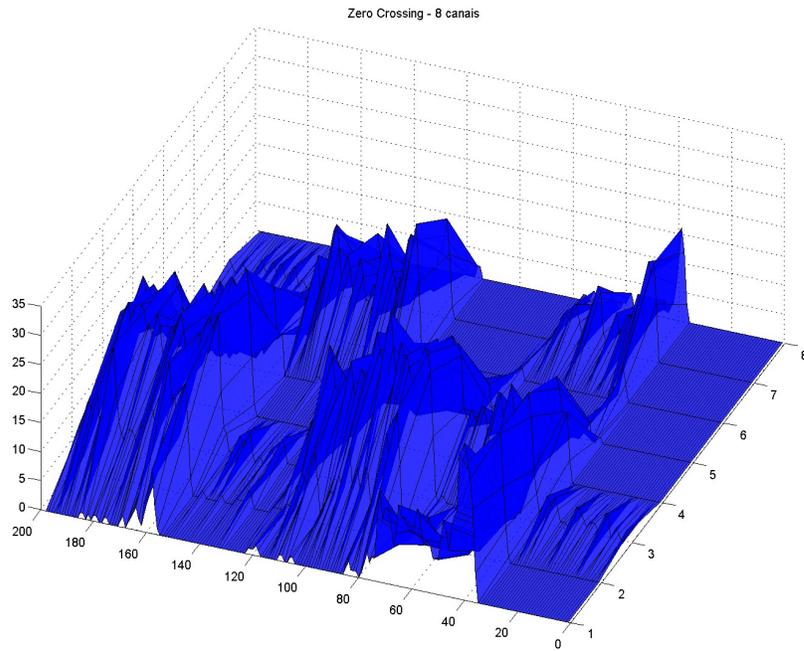


Figura B.7: Zero Crossing - 8 canais - 5 gestos.

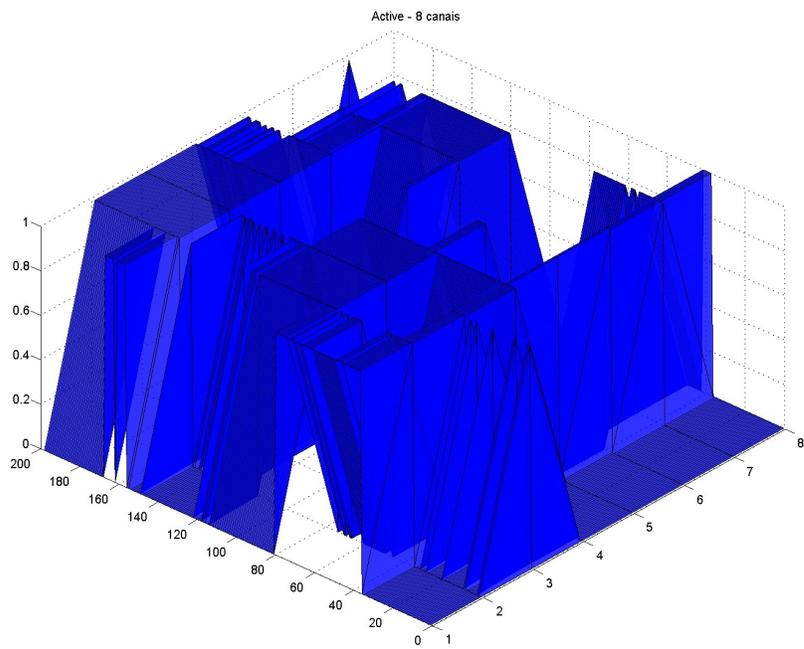


Figura B.8: Active - 8 canais - 5 gestos.

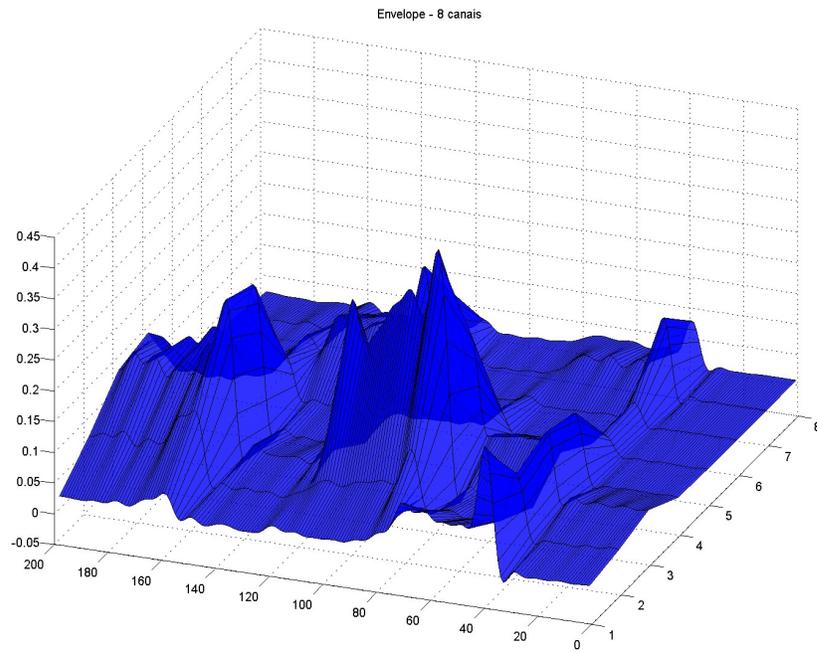


Figura B.9: Envelope - 8 canais - 5 gestos.

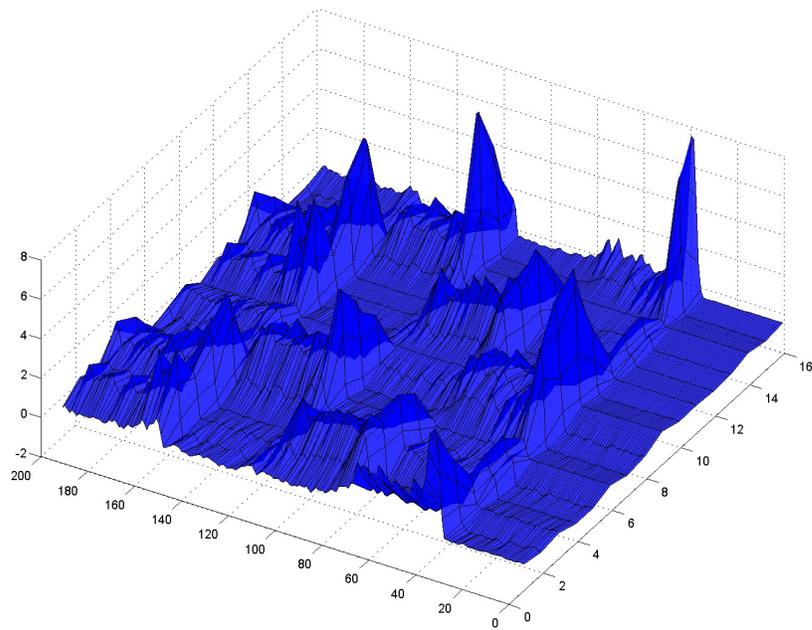


Figura B.10: RMS e Variância com média zero e normalizadas pelo desvio padrão - 8 canais - 5 gestos.

# C FEATURES PARA 9 GESTOS

---

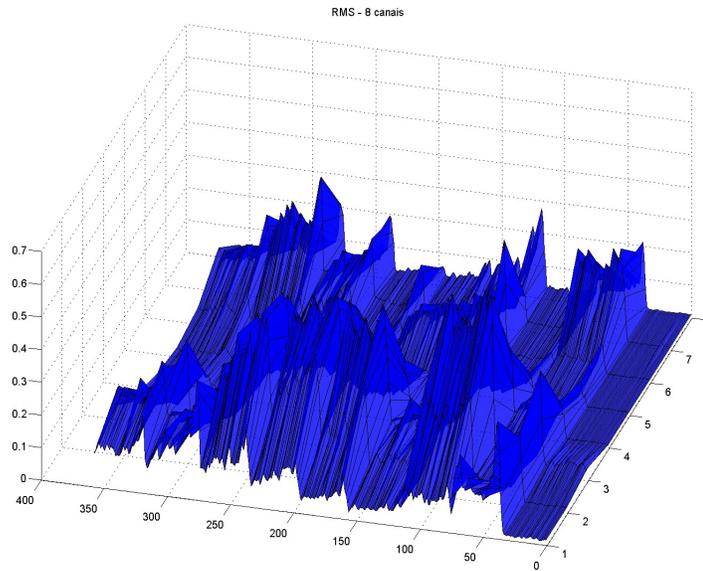


Figura C.1: RMS - 8 canais - 9 gestos.

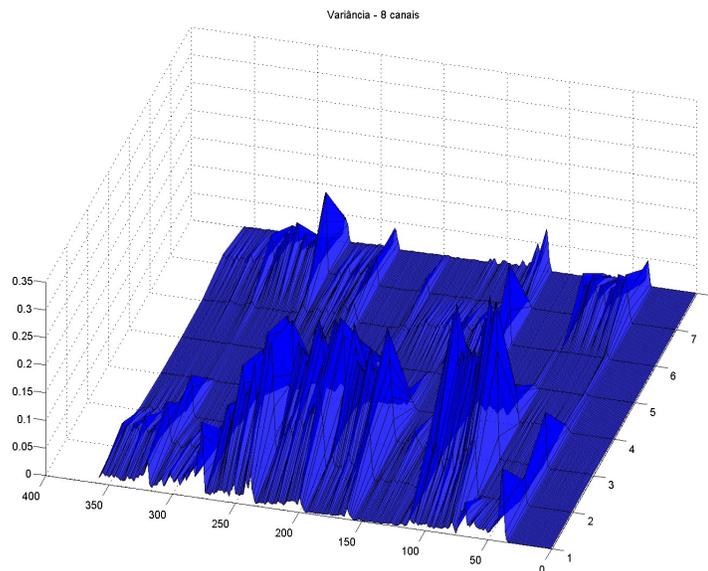


Figura C.2: Variância - 8 canais - 9 gestos.

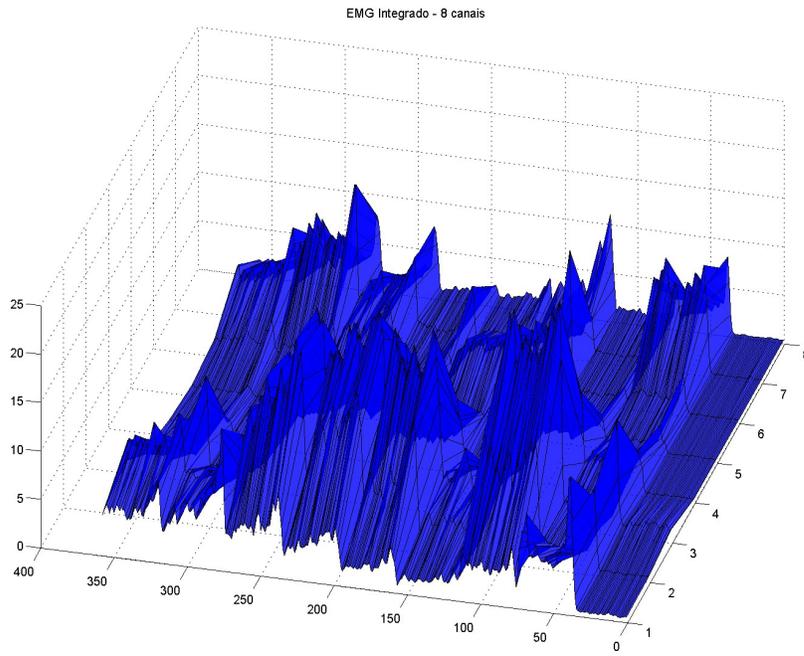


Figura C.3: EMG Integrado - 8 canais - 9 gestos.

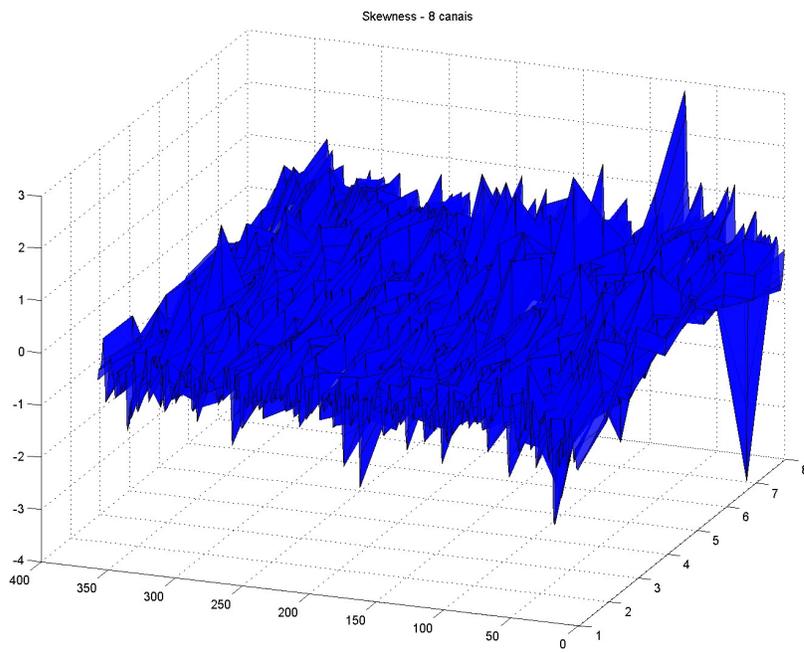


Figura C.4: Skewness - 8 canais - 9 gestos.

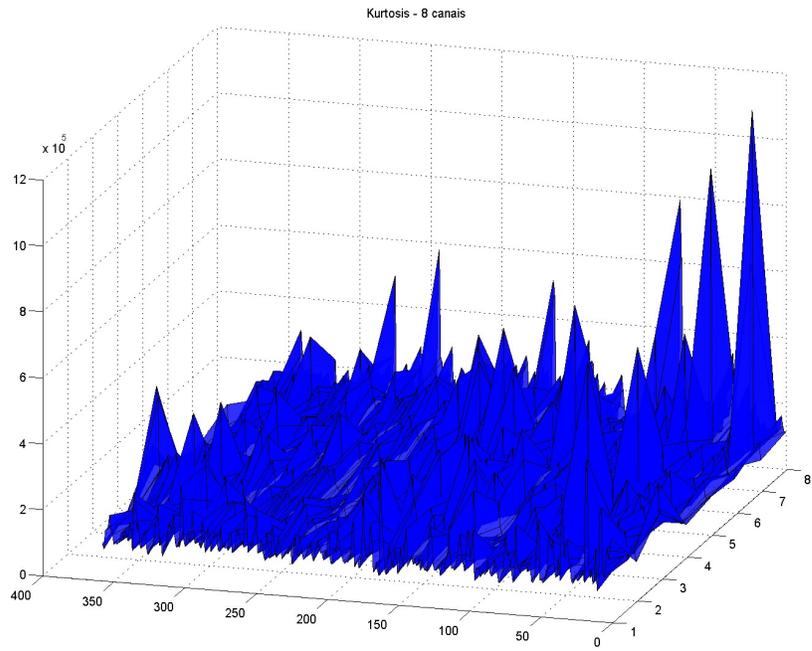


Figura C.5: Kurtosis - 8 canais - 9 gestos.

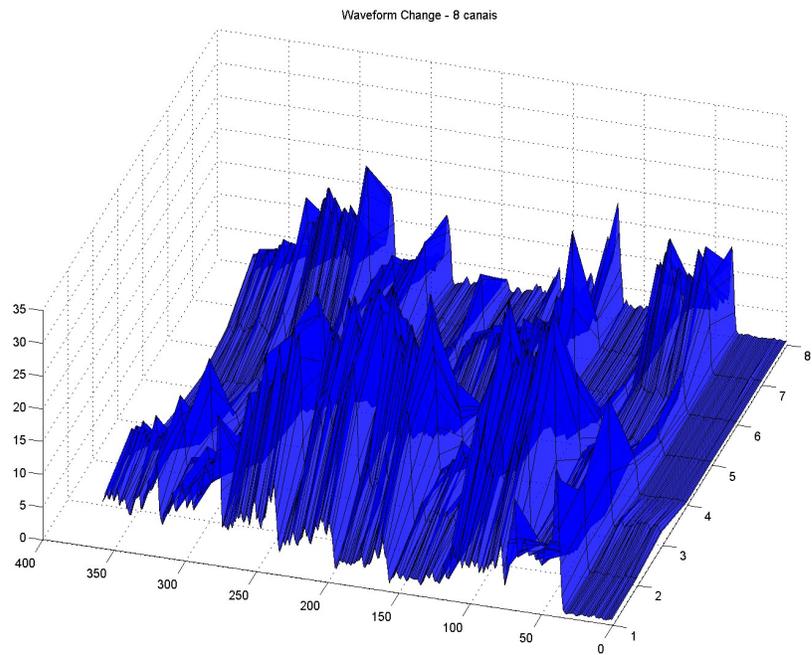


Figura C.6: Waveform Change - 8 canais - 9 gestos.

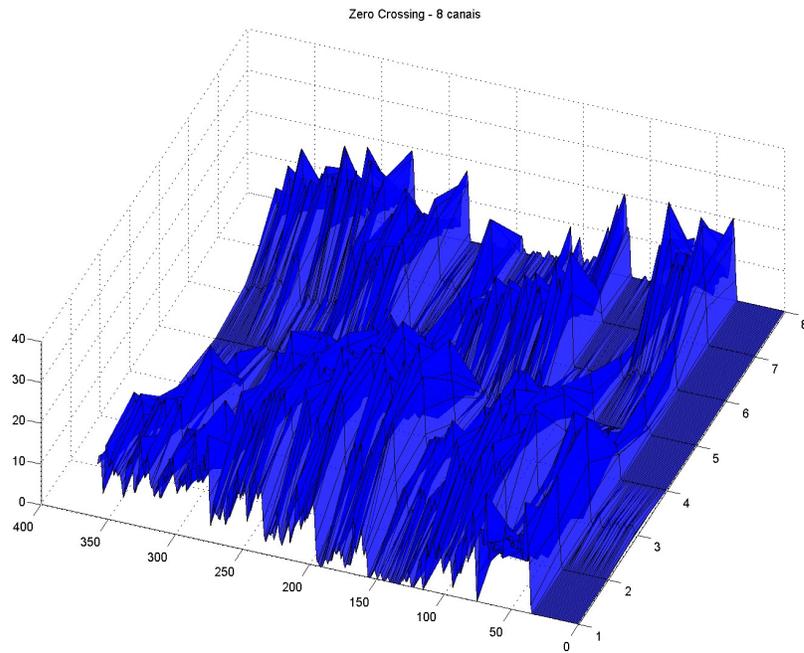


Figura C.7: Zero Crossing - 8 canais - 9 gestos.

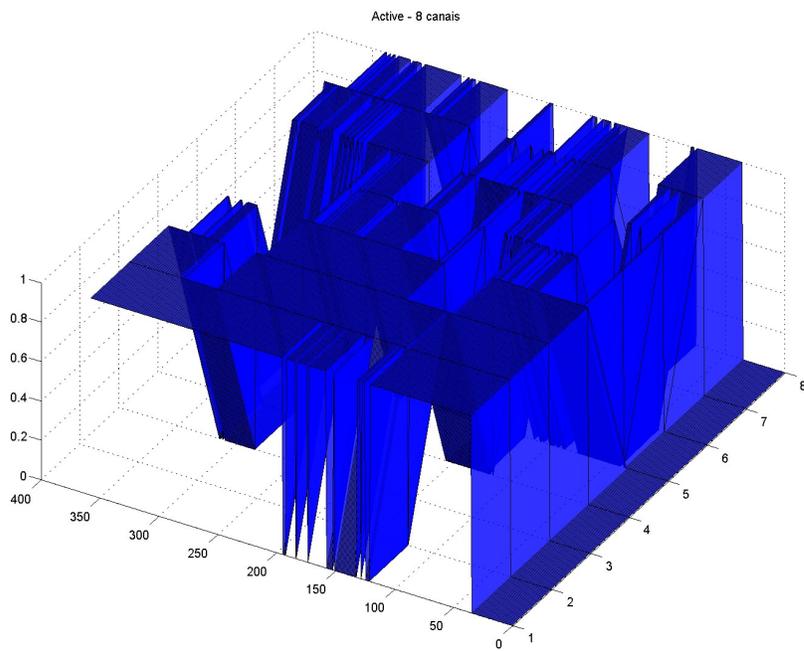


Figura C.8: Active - 8 canais - 5 gestos.

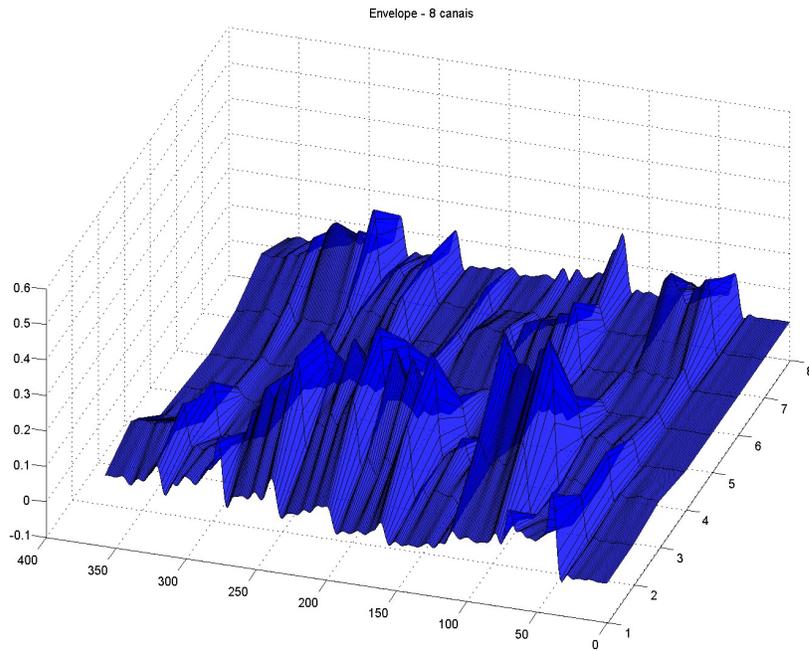


Figura C.9: Envelope - 8 canais - 9 gestos.

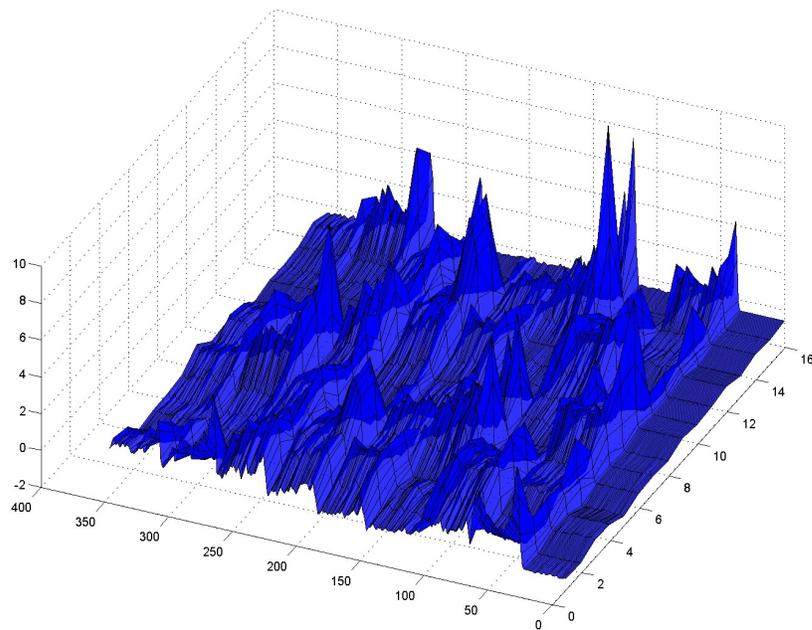


Figura C.10: RMS e Variância com média zero e normalizadas pelo desvio padrão - 8 canais - 9 gestos.