

CENTRO UNIVERSITÁRIO DA FEI
GIULIANO ALVES DA SILVA

**ANÁLISE MULTIVARIADA DO SINAL MIOELÉTRICO PARA
CARACTERIZAÇÃO DO TORQUE ISOMÉTRICO DO MÚSCULO
QUADRÍCEPS DA COXA**

São Bernardo do Campo-SP

2010

GIULIANO ALVES DA SILVA

**ANÁLISE MULTIVARIADA DO SINAL MIOELÉTRICO PARA
CARACTERIZAÇÃO DO TORQUE ISOMÉTRICO DO MÚSCULO
QUADRÍCEPS DA COXA**

Dissertação de Mestrado apresentada ao Centro
Universitário da FEI para obtenção do título de
Mestre em Engenharia Elétrica, orientada pelo
Prof. Dr. Carlos Eduardo Thomaz

São Bernardo do Campo, SP
2010

*À minha querida esposa Míriam,
por todo carinho e apoio. Aos meus
pais, irmãos e irmã.*

Agradecimentos

Ao meu orientador, Professor Dr. Carlos Eduardo Thomaz, por sua dedicação, pelo rigor, paciência e amizade. Agradeço por você se manter sempre otimista, me resgatando muitas vezes o ânimo para continuar em frente. Tenho certeza que esta realização não seria possível sem seu exemplo, inspiração e norte.

À Professora Dra. Maria Claudia Ferrari, por ter me apresentado este tema tão desafiador e interessante. Pelas longas horas de co-orientação, pesquisa e estudos, minha gratidão e carinho.

Ao Professor Dr. Rubens Corrêa Araújo, pela colaboração e por nos ceder a base de dados que viabilizou este trabalho, e ao Professor Dr. José Carlos pelas valiosas dicas e correções.

À minha família, por toda a paciência e compreensão quando, em função dos muitos compromissos profissionais ou acadêmicos, não pude estar em sua companhia.

Aos colegas de mestrado, pela companhia, pelas horas de estudo, por vivenciarmos juntos esta experiência. Minha gratidão à todos e em especial à Valquiria, pelo seu apoio, ao Rafael, Caruso, Danilo, Rodolfo e Horst pelas dicas com MatLab, MikTex e formatações. Quero agradecer também à Adriana e ao Ricardo, da secretaria do mestrado, pela atenção e carinho com que sempre nos acompanharam.

Aos amigos Allan Santos e João Lechinieski, pela ajuda na montagem dos arquivos e pela colaboração com a aquisição dos dados, ao Paulo Antonoff pelas dicas sempre úteis, pelas vezes em que precisei me ausentar e pude contar com vocês. Ao Felix, Peterson, Harald, Sadao e Vanderlei, pelo apoio que recebi de todos sempre que precisei.

Aos professores, Paulo Sérgio, Flávio, Bianchi e Paulo Santos, pela atenção e pelas aulas sempre interessantes, empolgantes e divertidas. Um agradecimento especial ao Paulo Sérgio pelas palavras de motivação em momentos importantes.

A ciência não é, e nunca será, um livro terminado. Todo progresso importante levanta novas questões. Dificuldades novas e mais profundas são reveladas posteriormente e a cada desenvolvimento.

Albert Einstein

Resumo

O estudo dos biopotenciais musculares vêm se desenvolvendo, impulsionado tanto pelas pesquisas para o diagnóstico dos distúrbios neuro-musculares, quanto pelo desenvolvimento de próteses mecânicas para amputados. O sinal mioelétrico constitui uma grande área de pesquisa dentro do estudo dos biopotenciais, fornecendo dados para o diagnóstico de tais distúrbios, além de constituir um meio para o controle de diversos tipos de dispositivos bio-mecânicos. O reconhecimento preciso do sinal mioelétrico é fundamental para sua utilização em tais sistemas, mas é também uma tarefa difícil devido a sua alta dimensionalidade e a natureza ruidosa dos dados registrados. Este trabalho tem como objetivo caracterizar o torque isométrico do músculo quadríceps da coxa, através de uma análise multivariada dos sinais mioelétricos correspondentes. Mais especificamente, a proposta deste estudo é investigar métodos de estatística multivariada para extração e detecção de padrões específicos contidos nesses sinais mioelétricos. Utilizando dados gerados em uma pesquisa anterior que avaliou a relação entre os parâmetros mioelétricos e o torque isométrico do músculo quadríceps da coxa, foi possível, através de transformações lineares e não lineares nos dados originais, caracterizar e classificar o torque isométrico, além de constatar que diferentes níveis percentuais de torque apresentam características determinísticas discriminantes. Estes resultados indicam que o reconhecimento do sinal mioelétrico pode ser melhorado através da utilização de técnicas de estatística multivariada para tratar conjuntos altamente dimensionais e com uma quantidade limitada de amostras.

Palavras Chave: Análise Estatística Multivariada, Análise das Componentes Principais, Caracterização de Sinais Eletromiográficos, Dados Multivariados, Eletromiografia, Redução de Dimensionalidade, Sinais Mioelétricos, Torque Isométrico.

Abstract

The study of muscle biopotentials has been developing, driven by research for diagnosis of neuromuscular disorders, and for the development of prostheses for amputees. The myoelectric signal consists in a major area of research within the study of biopotentials, providing data for diagnosis of such disorders, as well as providing means for controlling various types of bio-mechanical devices. The precise recognition of myoelectric signal is essential for its use in such systems, but also a difficult task due to the high dimensional and noisy nature of the recorded data. This work aims to characterize the torque of the quadriceps muscle through a multivariate analysis of myoelectric signals. More specifically, the purpose of this study is to investigate methods of multivariate statistics for the extraction and detection of specific characteristics contained in these myoelectric signals. Using data generated in a previous study that evaluated the relationship between the electromyographic parameters and the torque of the quadriceps muscles, it was possible, using linear and nonlinear transformations in the original data, to characterize and to classify the isometric torque, as well as notice that different percentage levels of torque shows discriminant characteristics. These results indicate that recognition of the myoelectric signal can be improved by using multivariate statistical techniques to handle high-dimensional sets and a limited number of samples.

Keywords: Multivariate Statistical Analysis, Principal Component Analysis, Electromyographic Signals Characterization, Multivariate Data, Electromyography, Dimensionality Reduction, Myoelectric Signals, Isometric Torque.

Lista de Figuras

2.1	Experimento conduzido por Galvani, em 1786, que procurava estabelecer a relação entre a eletricidade e o movimento muscular. Fonte [36].	18
2.2	Pilha voltaica, desenvolvida por Alessandro Volta, utilizando discos metálicos separados por um meio dielétrico.	20
2.3	Kymógrafo, desenvolvido por Carlo Matteucci para registrar os discretos sinais elétricos gerados pelos músculos.	21
2.4	Exemplo de um sinal EMG. O sinal mioelétrico inicia com uma baixa amplitude e se expande à medida em que a força aplicada no músculo também aumenta, porém de forma não linear. Fonte [16].	24
2.5	Representação de uma unidade motora, estrutura básica no processo de acionamento do músculo, com o neurônio motor localizado na medula e conectado às fibras musculares do músculo esquelético por meio de axônios, que se expandem como parte do nervo.	25
2.6	Exemplo de estrutura do músculo esquelético, com o detalhe da junção entre o osso e o tendão e dos núcleos das fibras musculares que são inervadas pelos neurônios-motores.	26
2.7	Arcabouço típico utilizado para o reconhecimento e classificação de sinais EMG, com as etapas de aquisição do sinal mioelétrico, a extração das características, a classificação e o reconhecimento do sinal mioelétrico.	35
3.1	Karl Pearson.	45
3.2	Ilustração da interpretação geométrica das componentes principais com dois exemplos de distribuição dos dados, uma (a) com variância significativa descrevendo um espalhamento elipsoidal, onde as componentes principais descrevem os eixos de maior variância dos dados, e outra (b) com uma variância homogênea dos dados, impossibilitando uma boa representação do conjunto em uma dimensão menor que a original. Fonte: adaptado de [54].	50
3.3	Demonstração do KPCA onde os dados originais, inicialmente representados em um espaço não linear, são mapeados linearmente em um novo espaço amostral. Fonte: adaptado de [28]).	51
3.4	Ronald Aylmer Fisher.	53
3.5	Ilustração do LDA para um conjunto de dados com dois grupos, nota-se o espalhamento dos dados com seus pontos projetados em uma linha na direção \hat{a} , que varia até que esses grupos estejam maximamente separados. Fonte: adaptado de [54].	56
4.1	Exemplo de eletrodo de superfície aderente à pele, com um polo positivo e um negativo, para aquisição de sinais EMG.	61

4.2	Exemplo de eletrodos de superfície aderente à pele, para aquisição de sinais EMG. Cabo com eletrodos para múltiplos canais.	61
4.3	Ilustração do músculo quadríceps da coxa composto pelos músculos reto-femoral, vasto lateral, vasto medial oblíquo e vasto medial longitudinal.	63
4.4	Dinamômetro isocinético Biodex System 3. Ilustração do experimento, com os eletrodos posicionados nos pontos pré-definidos nos músculos RF, VL, VML e VMO. Fonte [49].	63
4.5	Ilustração do experimento. Durante o exercício realizado, o monitor do dinamômetro isocinético fornecia o feedback do torque que estava sendo gerado pelo voluntário, possibilitando o controle do experimento. Fonte [49].	65
4.6	Tela do monitor do dinamômetro isocinético. Referência para graduação do torque exercido durante a execução do exercício. Fonte: [49].	66
4.7	Exemplo ilustrando a organização dos dados registrados em arquivos individuais para cada voluntário em função do exercício executado.	67
4.8	Ilustração da organização dos dados correspondentes aos sinais mioelétricos na matriz de dados X formada pelos dados correspondentes a: 6 níveis percentuais do torque exercido, 4 músculos agonistas, 9 sujeitos e 6 ângulos de posicionamento da perna.	70
4.9	Ilustração da distribuição dos dados mioelétricos do músculo RF, VL, VML e VMO, para um voluntário, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 40% da CVIM durante contração isométrica, onde percebe-se uma boa simetria no espalhamento dos dados ainda que considerando amostras de diferentes músculos.	71
4.10	Ilustração da distribuição dos dados mioelétricos para o grupo T00, composto pelos músculos RF, VL, VML e VMO, para um voluntário, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 00% da CVIM. Pode-se observar aqui, um padrão diferente na distribuição dos dados, quando comparado às demais classes estudadas, o que justificou a remoção desta classe na formação da matriz de dados X.	72
4.11	Ilustração da distribuição dos dados mioelétricos para o grupo T20, composto pelos músculos RF, VL, VML e VMO, para um voluntário, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 20% da CVIM.	73
4.12	Ilustração da distribuição dos dados mioelétricos para o grupo T40, composto pelos músculos RF, VL, VML e VMO, para um voluntário, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 40% da CVIM.	73
4.13	Ilustração da distribuição dos dados mioelétricos para o grupo T60, composto pelos músculos RF, VL, VML e VMO, para um voluntário, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 60% da CVIM.	74
4.14	Ilustração da distribuição dos dados mioelétricos para o grupo T80, composto pelos músculos RF, VL, VML e VMO, para um voluntário, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 80% da CVIM.	74
4.15	Ilustração da distribuição dos dados mioelétricos para o grupo T100, composto pelos músculos RF, VL, VML e VMO, para um voluntário, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 100% da CVIM.	75

4.16	Imagem média do sinal mioelétrico, construída a partir da matriz de dados X, e utilizada para construção de um filtro para remoção dos intervalos correspondentes às pausas para repouso, efetuadas durante os exercícios, com I1 (5701 até 9301); I2 (26401 até 30001); I3 (45601 até 49601); I4 (66001 até 69001) e I5 (85801 até 89401).	76
4.17	Ilustração da distribuição dos dados mioelétricos para o grupo T40, composto pelos músculos RF, VL, e VMO VML, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 40% da CVIM.	78
4.18	Ilustração da distribuição dos dados mioelétricos do músculo quadríceps da coxa para o conjunto T40 no espaço tridimensional, utilizando as 3 componentes principais de maior valor X1, X2 e X3 após a transformação linear com o PCA. Ainda Não é possível perceber nenhum padrão que auxilie na discriminação das informações correspondentes aos músculos RF, VL, VML e VMO.	79
4.19	Distribuição dos dados mioelétricos do músculo quadríceps da coxa, para o conjunto X no espaço tridimensional, ilustração utilizando as 3 componentes principais de maior valor X1, X2 e X3. Após a transformação linear com o PCA é possível perceber algumas informações dos conjuntos de dados correspondentes aos músculos RF, VL, VML e VMO, mas visualmente ainda não é possível extrair qualquer informação expressiva.	79
4.20	Ilustração da distribuição dos dados mioelétricos do músculo quadríceps da coxa para o conjunto T40 no espaço tridimensional, utilizando as 3 componentes principais de maior valor X1, X2 e X3 após a transformação linear com o PCA. Ainda Não é possível perceber nenhum padrão que auxilie na discriminação das informações correspondentes aos músculos RF, VL, VML e VMO.	80
4.21	Ilustração da distribuição dos dados mioelétricos do músculo quadríceps da coxa para o conjunto T40 no espaço tridimensional, utilizando as 3 componentes principais de maior valor X1, X2 e X3 após a transformação linear com o PCA e o MLDA. Aqui já é possível uma análise visual dos dados, com o espalhamento correspondentes aos músculos RF, VL, VML e VMO em áreas bem definidas, o que sugere uma boa separabilidade dos dados.	81
4.22	Distribuição dos dados mioelétricos do músculo quadríceps da coxa, para o conjunto X, no espaço tridimensional, utilizando as 3 componentes principais de maior valor X1, X2 e X3 após a transformação linear com o PCA. De modo análogo ao conjunto T40, após a transformação linear do conjunto X com o PCA ainda não é possível distinguir características individuais correspondentes a 20%, 40%, 60%, 80% e 100% do torque percentual aplicado.	82
4.23	Distribuição dos dados mioelétricos do músculo quadríceps da coxa para o conjunto X no espaço tridimensional, utilizando as 3 componentes principais de maior valor X1, X2 e X3 após a transformação linear com o PCA e o MLDA. A Figura permite uma análise visual dos dados, com o espalhamento correspondentes aos níveis de torques percentuais aplicados caracterizados em áreas bem definidas, sugerindo uma boa separabilidade dos dados.	83
4.24	Ilustração da distribuição dos dados mioelétricos para o grupo T20, composto pelos músculos RF, VL, VML e VMO, com 9 voluntários, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 20% da CVIM, com as componentes principais X1, X2, e X3 explicando respectivamente 6,42%, 3,81% e 3,51% da variância total dos dados.	84

4.25	Ilustração da distribuição dos dados mioelétricos para o grupo T40, composto pelos músculos RF, VL, VML e VMO, com 9 voluntários, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 40% da CVIM, com as componentes principais X1, X2, e X3 explicando respectivamente 9,92%, 6,49% e 5,02% da variância total dos dados.	84
4.26	Ilustração da distribuição dos dados mioelétricos para o grupo T60, composto pelos músculos RF, VL, VML e VMO, com 9 voluntários, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 60% da CVIM, com as componentes principais X1, X2, e X3 explicando respectivamente 10,39%, 4,57% e 4,00% da variância total dos dados.	85
4.27	Ilustração da distribuição dos dados mioelétricos para o grupo T80, composto pelos músculos RF, VL, VML e VMO, com 9 voluntários, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 80% da CVIM, com as componentes principais X1, X2, e X3 explicando respectivamente 5,25%, 4,47% e 4,01% da variância total dos dados.	85
4.28	Ilustração da distribuição dos dados mioelétricos para o grupo T100, composto pelos músculos RF, VL, VML e VMO, com 9 voluntários, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 100% da CVIM, com as componentes principais X1, X2, e X3 explicando respectivamente 5,24%, 3,98% e 3,32% da variância total dos dados.	86
4.29	Ilustração da distribuição dos dados mioelétricos para a matriz de dados X, no espaço tridimensional utilizando as 3 componentes principais de maior valor, após transformação não linear dos dados através do KPCA.	92
4.30	Ilustração da distribuição dos dados mioelétricos para a matriz de dados X, no espaço tridimensional utilizando as 3 componentes principais de maior valor, após transformação não linear dos dados através do KPCA mais o MLDA. É possível discriminar visualmente as áreas correspondentes as classes 20%, 40%, 60%, 80% e 100% do torque percentual aplicado.	92
4.31	Resultados para a classificação do conjunto referente a matriz X de dados, utilizando-se um classificador não -linear com e sem o MLDA para a etapa de tratamento dos dados.	93
4.32	Comparação da acuidade para as taxas de classificação utilizando um classificador linear e um não linear, para a matriz de dados X, considerando os grupos de treinamento, para ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 20%, 40%, 60% 80% e 100% da CVIM.	98
4.33	Comparação da acuidade para as taxas de classificação utilizando um classificador linear e um não linear, para a matriz de dados X, considerando os grupos de teste, para os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 20%, 40%, 60% 80% e 100% da CVIM.	99
4.34	Análise visual do sinal mioelétrico bruto, antes da remoção do grupo correspondente a 0% da CVIM, no espaço tridimensional utilizando as 3 componentes principais de maior valor. No centro da figura pode-se perceber a classe correspondente ao nível percentual de torque aplicado 0%, sobreposto aos demais conjuntos.	101

4.35	Análise visual do sinal mioelétrico bruto, após a remoção do grupo correspondente a 0% da CVIM, no espaço tridimensional utilizando as 3 componentes principais de maior valor. Percebe-se que após a remoção do conjunto correspondente a 0% da CVIM, houve uma melhora visual na separabilidade dos demais conjuntos.	102
4.36	Análise visual do sinal mioelétrico bruto, no espaço tridimensional utilizando as 3 componentes principais de maior valor, após a inversão da parte negativa do sinal EMG.	103
4.37	Análise visual do sinal mioelétrico bruto, no espaço tridimensional utilizando as 3 componentes principais de maior valor, considerando toda a informação disponível, sem um pós processamento.	103

Lista de Tabelas

4.1	Tabela Posição Angular x Torque. Exemplo do cálculo efetuado para determinar os valores percentuais em cada nível de torque, considerando a primeira aquisição como 100% do valor da CVIM, calculou-se a faixa de torque e o intervalo de tolerância de $\pm 5\%$ do valor total da CVIM[49].	66
4.2	Tabela de resultados para classificação do grupo T1 utilizando modelo linear. . .	87
4.3	Tabela de resultados para classificação do grupo T2 utilizando modelo linear. . .	88
4.4	Tabela de resultados para classificação do grupo T3 utilizando modelo linear. . .	88
4.5	Tabela de resultados para classificação do grupo T4 utilizando modelo linear. . .	88
4.6	Tabela de resultados para classificação do grupo T5 utilizando modelo linear. . .	88
4.7	Taxa média de classificação para as classes T20, T40, T60, T80 e T100	89
4.8	Tabela de resultados para classificação do grupo T1 utilizando modelo linear. . .	89
4.9	Tabela de resultados para classificação do grupo T2 utilizando modelo linear. . .	90
4.10	Tabela de resultados para classificação do grupo T3 utilizando modelo linear. . .	90
4.11	Tabela de resultados para classificação do grupo T4 utilizando modelo linear. . .	90
4.12	Tabela de resultados para classificação do grupo T5 utilizando modelo linear. . .	90
4.13	Cross-Validation para a taxa de classificação para as classes T20, T40, T60, T80 e T100	91
4.14	Tabela de resultados para classificação do grupo T1 utilizando modelo não linear. . .	94
4.15	Tabela de resultados para classificação do grupo T2 utilizando modelo não linear. . .	94
4.16	Tabela de resultados para classificação do grupo T3 utilizando modelo não linear. . .	95
4.17	Tabela de resultados para classificação do grupo T4 utilizando modelo não linear. . .	95
4.18	Tabela de resultados para classificação do grupo T5 utilizando modelo não linear. . .	95
4.19	Taxas médias de classificação para as classes T20, T40, T60, T80 e T100	95
4.20	Tabela de resultados para classificação do grupo T1 utilizando modelo não linear. . .	96
4.21	Tabela de resultados para classificação do grupo T2 utilizando modelo não linear. . .	96
4.22	Tabela de resultados para classificação do grupo T3 utilizando modelo não linear. . .	97
4.23	Tabela de resultados para classificação do grupo T4 utilizando modelo não linear. . .	97
4.24	Tabela de resultados para classificação do grupo T5 utilizando modelo não linear. . .	97
4.25	Taxas médias de classificação para as classes T20, T40, T60, T80 e T100	97

Lista de Símbolos e Abreviaturas

<i>BFCC</i>	—	bíceps femoral cabeça curta.
<i>BFCL</i>	—	bíceps femoral cabeça longa.
<i>BMI</i>	—	<i>Brain Machine Interface</i> ou interface cérebro máquina.
<i>CRT</i>	—	<i>Cathodic Ray Tube</i> ou tubo de raios catódicos.
<i>CVIM</i>	—	contração voluntária isométrica máxima.
<i>CVSM</i>	—	contração voluntária sub-máxima.
<i>EEG</i>	—	eletroencefalograma.
<i>EMG</i>	—	eletromiografia.
<i>KEMG</i>	—	<i>Knetics Eletromiographic</i> ou eletromiografia executada durante movimento.
<i>KPCA</i>	—	<i>Kernel Principal Component Analysis</i> ou análise das componentes principais.
<i>LDA</i>	—	<i>Linear Determinant Analysis</i> ou análise das determinantes lineares.
<i>MLDA</i>	—	<i>Kernel Principal Component Analysis</i> ou análise das componentes principais.
<i>MUAP</i>	—	<i>Motor Unit Action Potencial</i> ou potencial de ação da unidade motora.
<i>MUAPT</i>	—	<i>Motor Unit Potencial Train</i> ou trem de potencial de ação da unidade motora.
<i>Nm</i>	—	Newton Metros.
<i>PCA</i>	—	<i>Principal Component Analysis</i> ou análise das componentes principais.
<i>RF</i>	—	reto femoral.
<i>SM</i>	—	semimembranáceo.
<i>ST</i>	—	semitendíneo.
<i>VL</i>	—	vasto-lateral.
<i>VML</i>	—	vasto-medial lateral.
<i>VMO</i>	—	vasto medial oblíquo.
λ	—	autovalor.
Λ	—	matriz diagonal de autovalores.
ϕ	—	autovetor.
Φ	—	matriz ortogonal de autovetores.
\mathfrak{R}^n	—	espaço amostral com dimensão n .
x_i	—	variável presente em um determinado conjunto de dados.
\bar{x}	—	média de todas as variáveis em um determinado conjunto de dados.
S	—	matriz de covariância S .
N	—	número total de amostras de um determinado conjunto de dados.

Sumário

Lista de Figuras	7
Lista de Tabelas	12
Lista de Símbolos e Abreviaturas	13
1 Introdução	16
1.1 Objetivo	17
1.2 Estrutura do trabalho	17
2 Contextualização e Revisão Bibliográfica	18
2.1 Breve Histórico	18
2.2 Eletromiografia	23
2.3 O Sinal Mioelétrico	25
2.4 Captação e Análise dos Sinais EMG	27
2.5 Técnicas Para Reconhecimento do Sinal Mioelétrico	30
2.6 Considerações Adicionais	41
3 Métodos de Análise Multivariada	43
3.1 Análise Multivariada	43
3.2 Análise das Componentes Principais	45
3.2.1 Introdução e Breve Histórico	45
3.2.2 Cálculo das Componentes Principais	46
3.2.3 Geometria das Componentes Principais	48
3.3 Análise de Discriminantes Lineares	53
3.3.1 Breve Histórico	53
3.3.2 Cálculo da Análise das Discriminantes Lineares	54
3.3.3 Geometria das Discriminantes Lineares	55
3.4 Considerações Complementares	58
4 Experimentos e Resultados	59
4.1 Base de Dados	59

4.1.1	Material	60
4.1.2	Procedimento	61
4.2	Experimentos	68
4.2.1	Composição da informação relevante para a caracterização do sinal EMG	68
4.3	Resultados	77
4.3.1	Análise visual empregando um modelo linear para tratamento dos dados	77
4.3.2	Taxa de reconhecimento para o classificador linear	87
4.3.3	Análise visual empregando um modelo não-linear para tratamento dos dados	91
4.3.4	Taxa de Reconhecimento Para o classificador não-linear	93
4.4	Discussão	100
5	Conclusão e Trabalhos Futuros	105
5.1	Trabalhos Futuros	106
	Bibliografia	107

Capítulo 1

Introdução

O estudo de biopotenciais musculares vem se desenvolvendo, impulsionado tanto pelas pesquisas que buscam um diagnóstico para os distúrbios neuro musculares, quanto pelo desenvolvimento de próteses mecânicas para amputados [51, 52]. O músculo é formado por células especializadas, capazes de contração e relaxamento, responsáveis pelo movimento muscular em conjunto com células especializadas que conduzem impulsos nervosos entre a membrana muscular e a medula, produzindo as contrações responsáveis pelo movimento [51, 17, 50]. Estes impulsos nervosos são denominados sinais bioelétricos, ou mioelétricos, em se tratando dos sinais provenientes das células musculares [16].

A caracterização do sinal mioelétrico constitui um novo campo de pesquisa, representando uma importante ferramenta no desenvolvimento de estudos recentes. Na verdade, a caracterização deste sinal é de fundamental importância para as pesquisas que envolvem o reconhecimento, a descrição e a padronização do movimento humano, e possui as mais variadas aplicações em campos tão distintos quanto a engenharia biomédica, a fisioterapia, a ortopedia, a biomecânica, a neurologia e a neuro psicologia [16, 51].

A característica essencialmente ruidosa e altamente dimensional do sinal mioelétrico, aliado às dificuldades no processo de aquisição tornam sua utilização difícil e às vezes limitada [17]. Além disso, o registro do sinal mioelétrico pode envolver quantidades massivas de informação, considerando a facilidade e a atual disponibilidade de espaço para o armazenamento de dados nas mais diversas mídias, o que constitui outro fator complicador ao lidar com os sinais mioelétricos. Entretanto, técnicas estatísticas recentes podem auxiliar no tratamento do sinal, reduzindo sua dimensionalidade e oferecendo uma interpretação matemática para os dados envolvidos, aumentando a gama de possibilidades para a sua utilização [23, 44].

A estatística multivariada trata a análise estatística simultânea de uma coleção de diversas variáveis randômicas, considerando o relacionamento que essas variáveis possuem entre si [7]. Essa abordagem, ainda pouco explorada para os sinais mioelétricos, ajuda a explicar conjuntos de dados altamente dimensionais.

1.1 Objetivo

O objetivo deste trabalho é caracterizar o torque isométrico do músculo quadríceps da coxa através do estudo de biopotenciais musculares. Mais especificamente, a proposta é investigar métodos de estatística multivariada para extração e detecção de padrões específicos contidos nos sinais mioelétricos. Esses sinais mioelétricos foram gerados em uma pesquisa anterior, que avaliou a relação entre os parâmetros eletromiográficos e o torque isométrico do músculo quadríceps da coxa.

1.2 Estrutura do trabalho

Este trabalho está dividido em 5 capítulos. O capítulo seguinte, capítulo 2, apresenta alguns princípios básicos de eletromiografia e do sinal mioelétrico, e uma revisão bibliográfica sucinta sobre o tema de estudo. O capítulo 3 descreve os métodos estatísticos utilizados para a caracterização e redução da dimensionalidade do sinal mioelétrico, apresentando as técnicas multivariadas de análise de componentes principais e análise de discriminantes lineares e não lineares. O capítulo 4 descreve a base de dados utilizada neste trabalho, além dos experimentos executados utilizando as técnicas estatísticas para a caracterização dos sinais mioelétricos, este capítulo traz também a apresentação e discussão dos resultados obtidos. Finalmente, o capítulo 5 traz as conclusões sobre as análises realizadas nessa dissertação e um plano de continuidade para possíveis trabalhos futuros. Por questões de padronização optou-se por manter os termos técnicos utilizados no texto na língua inglesa. As abreviações desses termos e suas respectivas traduções constam na lista de abreviações e símbolos.

Capítulo 2

Contextualização e Revisão Bibliográfica

2.1 Breve Histórico

A eletromiografia, apesar de constituir uma área de pesquisa científica relativamente nova, teve suas origens ainda no século XVII, com os estudos do Italiano Francesco Redi [16], mas foi em 1786, enquanto dissecava uma rã para seus experimentos, que o então anatomista e cirurgião da Universidade de Bolonha, Luigi Galvani, descobriu acidentalmente o que chamaria de eletricidade animal. Este experimento foi detalhadamente descrito por Galvani em seu artigo “De Viribus Electricitatis in Motu Musculari”, considerado o precursor da moderna eletromiografia [51].



Figura 2.1: Experimento conduzido por Galvani, em 1786, que procurava estabelecer a relação entre a eletricidade e o movimento muscular. Fonte [36].

A figura 2.1 ilustra um dos experimentos descritos por Galvani em seu artigo, onde decribe o momento em que se deparou com o fenômeno elétrico:

“Eu dissequei e preparei uma rã e coloquei-a em uma mesa, na qual havia uma máquina elétrica. Eu a desliguei totalmente dos condutores e a separei a uma boa distância. Quando por acidente, um dos meus auxiliares tocou levemente com o escalpelo o nervo medial exposto da rã, imediatamente todos os músculos do membro pareceram contrair-se de tal forma que apresentaram violentas convulsões. Mas outro dos assistentes, que estava presente quando eu fazia experimentos com eletricidade, pareceu observar que a mesma coisa ocorrera quando uma fagulha foi descarregada pelo condutor da máquina [36].”

Curioso a respeito do que havia observado, Galvani conduziu diversos experimentos procurando explicar a relação entre o movimento muscular e a eletricidade. Alterando as condições dos experimentos ele observou o movimento muscular sob a influência das fagulhas elétricas produzidas pelo eletróforo, pela eletricidade atmosférica ou mesmo pelo que acreditava ser a eletricidade inerente ao animal, nem sempre com resultados conclusivos:

“Quando eu apliquei a ponta do escalpelo novamente sobre o nervo, não obtive o movimento tanto quando uma fagulha era produzida, quanto quando a máquina estava parada. Mas o fenômeno aparecia apenas quando uma fagulha era produzida. Nós repetimos o experimento, sempre empregando o mesmo escalpelo, mas para nossa surpresa, quando uma fagulha se produzia, algumas vezes o movimento ocorria, e algumas vezes não [36].”

Contemporâneo de Benjamin Franklin e Alessandro Volta, Galvani lidava com equipamentos e conceitos elétricos ainda pouco desenvolvidos e não conseguiu perceber uma variável presente em seus estudos, as delicadas correntes elétricas produzidas pelas reações químicas nos objetos manipulados durante seus experimentos.

Alessandro Volta, físico italiano e colega de Galvani, beneficiou-se destes experimentos enxergando alí a energia gerada através das reações químicas que Galvani não conseguia ver dissociada da sua “eletricidade animal”. Volta, após várias discussões com Galvani sobre a origem da eletricidade como uma resposta química para o contato entre os diferentes tipos de metais, desenvolveu a pilha voltaica, que recebeu esse nome por tratar-se realmente de discos empilhados, feitos de metais diferentes e separados por um meio dielétrico.

Volta chamou a reação química envolvida no processo de “galvanismo”, em homenagem ao colega. Na figura 2.2 ¹ temos a representação da pilha desenvolvida por Volta [25].




Figura 2.2: Pilha voltaica, desenvolvida por Alessandro Volta, utilizando discos metálicos separados por um meio dielétrico.

Galvani abriu caminho para a eletrofisiologia e a neurofisiologia moderna, caracterizando os nervos como condutores elétricos, responsáveis pelos movimentos produzidos pelos músculos e desenvolvendo o conceito da bioeletricidade. Seu trabalho influenciou e estimulou as pesquisas que se seguiram.

Intrigado com o trabalho de Galvani, o físico e neurofisiologista italiano Carlo Matteucci iniciou em 1830 uma série de experimentos baseados na hipótese da “eletricidade animal”, demonstrada por Galvani, que se seguiriam até sua morte em 1865. Utilizando um sensível galvanômetro de Nobeli, Matteucci provou que tecidos musculares feridos, quando excitados, geravam um fluxo contínuo de corrente elétrica, demonstrando inclusive que ao empilhar o tecido, era possível multiplicar esse fluxo elétrico, de modo análogo aos discos metálicos adicionados em uma pilha voltaica, provando definitivamente a hipótese de Galvani sobre a existência da bioeletricidade. Mais tarde, em 1846, Matteucci inventou um dispositivo mecânico capaz de registrar um deslocamento físico, resultante de uma contração muscular, chamado Kymógrafo, representado na figura 2.3² [25].

¹Fonte: <http://www.forp.usp.br/restauradora/oclusao/lapese>. Acesso em 15/02/2009.

²Fonte: <http://chem.ch.huji.ac.il/history/matteucci>. Acesso em 02/03/2009.




Figura 2.3: Kymógrafo, desenvolvido por Carlo Matteucci para registrar os discretos sinais elétricos gerados pelos músculos.

Em 1847, as publicações de Matteucci sobre os resultados de suas observações chamaram a atenção de Johannes Muller, um famoso fisiologista médico e professor da universidade de Berlim, que não aceitava a ideia de que a eletricidade estivesse envolvida nas funções normais do nervo, ainda que pudesse estimulá-lo artificialmente. Muller passou as observações de Matteucci para um de seus melhores alunos, Emil du Bois-Reymond, solicitando a ele que tentasse reproduzir os resultados de Matteucci. Um ano depois, Reymond não só reproduziu estes resultados como foi além, demonstrando que quando um nervo é estimulado, um impulso elétrico mensurável forma-se no local do estímulo e propaga-se em alta velocidade através do nervo provocando a contração muscular. Mais tarde, este impulso seria definido por ele e Muller como “potencial de ação” do nervo [25].

Entre 1831 e 1875, Guillaume Benjamin Amand Duchenne, um neurofisiologista francês, criou o eletrodiagnóstico e a eletroterapia, estudou o efeito dos estímulos elétricos sobre nervos e músculos enfermos e classificou diversos tipos de atrofas e paralisias causadas por alterações nervosas. Duchenne foi o primeiro a descrever várias desordens neurológicas e fisiológicas, e a desenvolver o tratamento para elas [25].

Em 1922, Gasser e Erlanger usaram um osciloscópio para mostrar o sinal elétrico dos músculos. Devido à natureza estocástica do sinal mioelétrico, apenas informações

rudimentares poderiam ser obtidas destas observações. Este quadro melhorou entre os anos de 1930 e 1950, quando os pesquisadores desenvolveram uma variedade maior de eletrodos para o estudo dos músculos. A partir dessa época, o desenvolvimento de novos estudos e tecnologias possibilitaram o avanço da eletromiografia e a compreensão dos biopotenciais musculares [44].

Herbert Henri Jasper, neurologista canadense, criou o primeiro eletromiógrafo e o eletrodo de agulha unipolar. Nos anos 50, surgiram sistemas capazes de mostrar e registrar as formas de onda capturadas em cada canal disponível. Estes sistemas já apresentavam amplificadores e filtros, ligados a cada canal, para tratar o sinal mioelétrico enviado ao monitor CRT (*Catodic Ray Tube*). Este sinal poderia também ser registrado em filmes de papel, o que permitia uma análise mais apurada dos dados após o processamento, em laboratório, do filme utilizado.

O uso clínico do sinal mioelétrico de superfície, para o tratamento de distúrbios específicos dos músculos, começou nos anos 60, após a utilização dos recém inventados transistores, no final dos anos 40, e das placas de circuito integrado, tornando estes aparelhos eletrônicos mais confiáveis. Hardyck e seus pesquisadores foram os primeiros médicos, em 1966, a utilizar efetivamente os sinais mioelétricos.

No início dos anos 80, Cream e Steger introduziram o método clínico para varrer uma variedade de músculos utilizando um eletrodo. Apenas a partir de meados dos anos 80, com a invenção dos dispositivos de memória eletrônica, muitas possibilidades se abriram para modelagem e confecção dos sistemas eletromiográficos. A partir daí, a tecnologia evoluiu o suficiente para permitir a produção em série de eletrodos, amplificadores e dispositivos comercialmente acessíveis. Os sistemas tornaram-se maiores e mais complexos, quando comparados às gerações anteriores.

Com os sistemas digitais incorporando as novas gerações de equipamentos eletromiográficos, muitos pesquisadores começaram a utilizá-los em conjunto com os computadores disponíveis na época. Isto tornou o poder de processamento dos sinais registrados muito maior. Com o advento da micro-informática e com os avanços no hardware disponível, a partir dos anos 90, foi possível passar para o microcomputador todas as funções de processamento relacionadas ao sinal mioelétrico, com benefícios tais como a alta capacidade de armazenamento dos registros, processamento imediato do sinal registrado e a capacidade de exibição gráfica dos resultados obtidos. Esta união permitiu aos pesquisadores

implementar novas formas de processamento do sinal mioelétrico, criando uma nova área de pesquisa através da eletromiografia [44].

A história recente da eletromiografia traz nomes como os de John V. Basmajian, cientista canadense criador dos eletrodos intramusculares de fio, mais confortáveis que os de agulha podendo ser utilizados por um período de tempo maior, e Carlo J. De Luca, engenheiro biomédico e Phd, provavelmente o nome mais influente na história recente da eletromiografia, tendo chamado a atenção para os problemas na compreensão do sinal mioelétrico, bem como para a facilidade atual de sua aquisição e a grande gama de aplicações possíveis.

2.2 Eletromiografia

A eletromiografia consiste basicamente na detecção, registro e análise dos sinais elétricos provenientes das contrações musculares. Este termo refere-se ao sinal eletromiográfico, ou simplesmente EMG, um termo mais comumente utilizado no passado, quando a única maneira de capturar o sinal para estudos subsequentes era através de sua representação em gráficos. Hoje é possível armazenar estes dados nos mais diversos meios, o que torna esta nomenclatura um tanto limitada. Atualmente é mais comum referir-se ao termo como sinal mioelétrico, mas o termo “sinal eletromiográfico” é ainda muito utilizado, principalmente no meio clínico [16].

Os sinais elétricos, transmitidos por unidades motoras aos músculos esqueléticos, controlam a posição e os movimentos dos membros, enquanto viajam entre o sistema nervoso central e os músculos [51]. Ao registrar e estudar estes sinais, através da eletromiografia, é possível determinar padrões de interesse e utilizar essas informações para controlar uma grande variedade de dispositivos. Infelizmente estas informações não são totalmente confiáveis, devido à grande suscetibilidade ao ruído e aos dados redundantes, inerentes ao sinal mioelétrico.




Figura 2.4: Exemplo de um sinal EMG. O sinal mioelétrico inicia com uma baixa amplitude e se expande à medida em que a força aplicada no músculo também aumenta, porém de forma não linear. Fonte [16].

A Figura 2.4 mostra um exemplo de sinal mioelétrico, que inicia com uma baixa amplitude e que se expande, revelando potenciais individuais associados à contração de fibras musculares também individuais, ou pequenos grupos destas. À medida em que a força produzida pelo músculo aumenta, aumenta também a quantidade de fibras musculares ativadas, assim como as taxas de disparo dessas fibras. A amplitude do sinal aumenta proporcionalmente, porém de forma não linear [15, 14, 34].

A possibilidade de detectar alterações no sinal EMG, como resultado de mudanças no sistema neuromuscular, através da utilização de eletrodos invasivos ou de superfície, justifica o crescente número de pesquisas que se desenvolvem nessa área. Apesar das dificuldades para a caracterização deste sinal, sua utilização permite o desenvolvimento de sistemas aplicados em áreas tão variadas quanto distintas. Pesquisas na área da medicina, engenharia biomecânica, neurofisiologia, psicologia, fisioterapia e mesmo aplicações industriais beneficiam-se do estágio tecnológico atual em que se encontram as pesquisas e aplicações do sinal mioelétrico, fazendo deste uma excelente fonte de estudos, entretanto, é o seu potencial de desenvolvimento o que empolga e impulsiona sua pesquisa [16].

2.3 O Sinal Mioelétrico

O sinal mioelétrico é a manifestação elétrica da ativação neuromuscular associada à contração muscular [16], e tem sua origem nos neurônios motores, representados na Figura 2.5³. Estas células, localizadas na medula, têm longos axônios que correm como parte dos nervos até o músculo esquelético, representado na Figura 2.6⁴, onde cada axônio se espalha conectando-se a um determinado número de fibras musculares. Cada neurônio-motor pode, desse modo, inervar simultaneamente um grupo de fibras musculares. Esta estrutura de neurônios-motores acoplados às fibras musculares forma a unidade funcional básica no processo de acionamento do músculo denominada unidade motora. Dependendo do seu tamanho, um músculo pode ser composto por dezenas ou muitas centenas de unidades motoras [51].

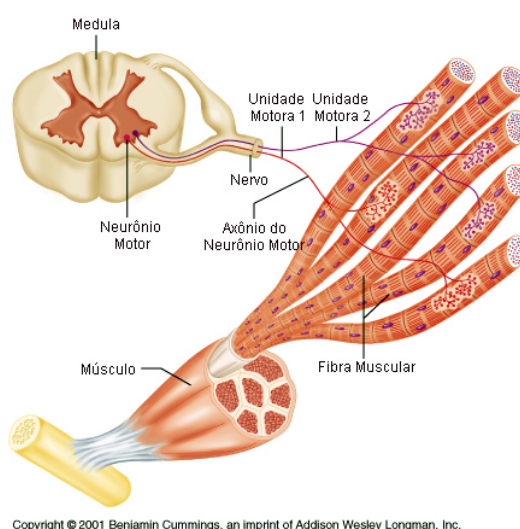


Figura 2.5: Representação de uma unidade motora, estrutura básica no processo de acionamento do músculo, com o neurônio motor localizado na medula e conectado às fibras musculares do músculo esquelético por meio de axônios, que se expandem como parte do nervo.

³Fonte: <http://faculty.etsu.edu/forsman/Histology>. Acesso em 06/04/2009.

⁴Fonte: <http://sabereletronica.com.br/secoes/leitura/556>. Acesso em 18/11/2008.

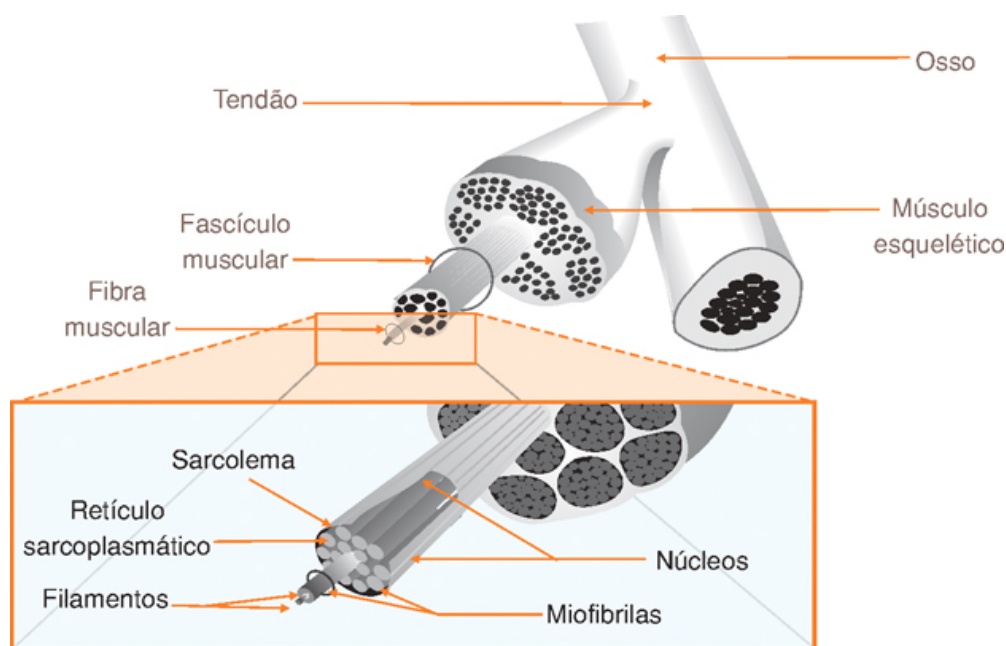


Figura 2.6: Exemplo de estrutura do músculo esquelético, com o detalhe da junção entre o osso e o tendão e dos núcleos das fibras musculares que são inervadas pelos neurônios-motores.

Ao ser ativada pelo sistema nervoso central, uma unidade motora produz um impulso elétrico que se propaga pelo axônio e chega às fibras musculares. Com este estímulo, neurotransmissores são liberados causando ondas de despolarização propagadas ao longo dessas fibras. Como o tecido nas proximidades das fibras musculares são condutores, esta despolarização simultânea irá induzir um efeito elétrico perceptível a um eletrodo posicionado em suas vizinhanças.

O sinal captado pelo eletrodo é chamado potencial de ação da unidade motora, ou MUAP (do inglês, *“Motor Unit Action Potential”*), e constitui a unidade fundamental do sinal mioelétrico [51]. O MUAPT *“Motor Unit Action Potencial Train”*, ou trem de potencial de ação da unidade motora, é a repetição contínua do potencial de ação, que define e permite a descrição da contração contínua do músculo. A forma de onda de um potencial de ação dentro de um MUAPT permanecerá constante se a relação geométrica entre as fibras musculares ativas permanecer constante, se as propriedades do eletrodo não mudarem e se não houver uma mudança bioquímica significativa no tecido muscular. Alterações bioquímicas dentro do músculo podem alterar a velocidade de condução da fibra e as propriedades elétricas do tecido muscular [14]. Seria correto dizer que o processo fisiológico envolvido na ativação de um músculo é um indicador válido do seu nível de ativação, de modo que este sinal pode ser utilizado para o estudo da coordenação e do

controle dos movimentos. Isto sugere uma conexão entre o nível do sinal EMG e a força exercida pelo músculo [51].

2.4 Captação e Análise dos Sinais EMG

A detecção precisa do sinal mioelétrico é um aspecto importante na pesquisa de biopotenciais musculares. A crescente demanda para a utilização dos sinais mioelétricos em movimentos dinâmicos levou ao desenvolvimento da tecnologia necessária para o registro preciso do sinal. Johnson et al. [54] afirma que a amplificação e o registro do sinal KEMG (*Knetics Eletromiographic*) sem a contaminação por interferências elétricas ou ruído, é um problema pois o nível do sinal captado pelos eletrodos é muito baixo, na ordem de micro ou milivolts, sendo suscetível a interferências elétricas diversas e ao movimento dos dispositivos utilizados [54]. No estudo clássico do sinal EMG, a interferência gerada pelo movimento dos dispositivos de captura podem ser evitados, pois normalmente seu registro se dá em um ambiente controlado e em condições estáticas. No estudo para a caracterização do movimento, entretanto, é necessário lidar com este tipo de interferência.

O método mais comum para captação destes sinais é através da utilização de eletrodos conectados a eletromiógrafos. Esses eletrodos podem ser do tipo invasivo, cuja utilização implica na inserção do dispositivo diretamente no músculo, através da pele, e do tipo não invasivo, aplicados diretamente sobre a pele. É preciso, então, considerar as vantagens de um e outro método, pois a detecção de sinais EMG implica em lidar com ruídos na captação dos sinais. Se por um lado o eletrodo invasivo é desconfortável, permite também a captação de sinais de forma precisa, podendo captar o potencial de ação de uma única unidade motora. Isto significa o registro de um sinal com um nível de ruído muito menor quando comparado aos eletrodos não invasivos.

Segundo De Luca [15], a amplitude do sinal EMG, durante a aquisição utilizando eletrodos não invasivos, depende de fatores tão diversos quanto a força aplicada, o tempo considerado, o diâmetro da fibra muscular, sua distância em relação ao local de captação, a configuração do tecido subcutâneo e as propriedades do eletrodo utilizado. Sabe-se também que a temperatura intra-muscular, a fadiga, o fluxo sanguíneo, a velocidade de encurtamento e alongamento das fibras musculares e a magnitude da tensão mecânica exercida podem alterar as características do sinal mioelétrico [50, 56]. Essa técnica de captação de sinais EMG por eletrodos não invasivos, entretanto, é muito mais prática e

confortável na sua utilização, e por isso mais viável tanto técnica quanto comercialmente.

Outro aspecto importante é a detecção de eventos discretos no sinal EMG, como a mudança de fase no padrão de atividade associado com o início de uma resposta motora rápida. Diversos métodos vêm sendo propostos para a detecção de início e fim no tempo de disparo do músculo [44].

Um método comum para resolver eventos moto-relacionados dos sinais EMG consiste na inspeção visual por observadores treinados. O método *single-threshold*, que compara o sinal EMG com um valor de limiar fixo, é o mais intuitivo e comum para o ajuste do tempo de disparo da atividade de contração muscular. Esta técnica baseia-se na comparação de sinais EMG retificados com um valor de amplitude limiar, cujo nível depende do ruído de fundo. Este método pode ser útil para superar alguns dos problemas relacionados à inspeção visual. Entretanto, geralmente não se mostra satisfatório, uma vez que os resultados medidos dependem da escolha do limiar de comparação e da heurística utilizada para encontrá-lo.

Para superar os problemas apresentados pelo método *single-threshold*, Bornato et al. [46] apresentaram o método *double-threshold detection* em 1998. Este método é superior ao *single-threshold* porque produz uma probabilidade maior de detecção, possibilitando ao usuário adotar a relação entre o alarme falso e a probabilidade de detecção com um grau maior de liberdade do que o *single-threshold*. O usuário pode ajustar o detector de acordo com diferentes critérios, adaptando assim sua performance às características específicas de cada sinal e a sua aplicação.

Um outro método, proposto por Lanyi e Adler em 2004 [57], argumentava que o método proposto por Bornato [46] era complexo e computacionalmente dispendioso. Eles propuseram um novo algoritmo, baseado no método *double-threshold*, simplesmente fixando o valor do segundo limiar durante a detecção do sinal. Este valor foi fixado em 1, o que faz com que o *double-threshold* na realidade trabalhe como o *single-threshold*, porém com mais um parâmetro para controle. O método de Lanyi e Adler [57] mostrou ser mais estável e eficiente, com um custo computacional menor.

O sinal mioelétrico é essencialmente ruidoso e sujeito à interferência dos sinais enviados por outros músculos [37, 16]. Este sinal varia de acordo com a força aplicada e o tempo estimado. Na verdade, a amplitude do sinal capturado pode variar randomicamente acima e abaixo do valor zero. A simples variação deste sinal não traz nenhuma informação útil.

É necessário, então, fazer uso de determinadas técnicas, tal como a retificação de sinais, que possibilitem uma análise mais apurada do sinal EMG.

A retificação dos sinais EMG, antes de efetuar sua análise, é um método bem difundido e simples para minimizar as restrições inerentes à utilização de sensores não invasivos. O processo de retificação do sinal mioelétrico envolve o conceito de interpretar apenas as deflexões positivas do sinal. Isto pode ser conseguido tanto pela eliminação dos sinais negativos (retificação de meia onda) quanto pela inversão dos valores negativos (retificação de onda completa). Esta segunda técnica é mais comumente utilizada por considerar a retenção de toda a energia do sinal [16].

A operação matemática equivalente a regularizar o sinal mioelétrico seria extrair a média dos valores registrados, desta forma os valores mais discrepantes seriam removidos. A expressão matemática para calcular a média do sinal EMG retificado é: $|m(t)|_{t_j-t_i} = \frac{1}{t_j-t_i} \int_{t_i}^{t_j} |m(t)| dt$, onde t_i e t_j são pontos no tempo sobre os quais a integração e a média são executadas. Quanto menor o intervalo de tempo, menor a regularização do valor médio [16].

Derivações matemáticas de parâmetros dependentes do tempo e da força aplicados indicam que a raiz quadrada da média aritmética, ou simplesmente valor RMS (*root mean squared*), provê um valor mais rigoroso do conteúdo da informação porque mede a energia do sinal. A expressão matemática para o cálculo do valor RMS é: $|f(t)|_{rms} \int_{t_i}^{t_j} = \sqrt{\frac{1}{t_j-t_i} \int_{t_i}^{t_j} |f(t)|^2 dt}$, onde t_i e t_j são pontos no tempo. Sua utilização era escassa no passado, mas crescente hoje em dia, provavelmente devido a maior disponibilidade de dispositivos eletrônicos capazes de executar operações RMS e à crescente competência técnica na eletromiografia. Este valor é útil quando é necessário avaliar o tempo de ativação do músculo, bem como medir seu nível de ativação e quantificar a força gerada pelo mesmo [16].

2.5 Técnicas Para Reconhecimento do Sinal Mioelétrico

O sinal mioelétrico vem sendo amplamente utilizado, tanto na prática de exames clínicos quanto na área da reabilitação física. A análise do sinal EMG proporciona um entendimento mais efetivo da estratégia de recrutamento muscular, implementado pelo sistema nervoso central, para o controle motor, além de constituir uma ferramenta valiosa para diagnosticar desordens neuromusculares. Na verdade, diversos trabalhos [6, 9, 5, 8, 51, 55, 38] propõem a análise do sinal EMG para estudos anatômicos e para a reabilitação de indivíduos com disfunções moto-relacionadas, além da sua utilização para o controle de próteses, dispositivos robóticos, biomecânicos e de interfaces homem-máquina. A viabilidade da utilização do sinal mioelétrico para a análise do movimento e para o controle de dispositivos elétricos deve-se ao fato de que diferentes movimentos implicam em diferentes modos de ativação muscular relacionados com estes movimentos, que se refletem em diferentes “assinaturas” ou padrões de sinais mioelétricos [52, 18].

Segundo Kleyssen et al. [51], uma das primeiras aplicações da análise e processamento do movimento humano foi o trabalho desenvolvido pelo grupo da Universidade de Berkeley, na Califórnia, após a Segunda Guerra Mundial, estimulada pelas necessidades da época. Esse grupo de pesquisadores conduziu uma extensiva análise biomecânica do movimento humano, para apoiar o desenvolvimento e a evolução de dispositivos protéticos. Desde então, o estudo e a aplicação clínica da análise do movimento constituem uma importante área de trabalho e pesquisa.

A despeito da relevância sócio-econômica para aplicação das técnicas de análise do sinal mioelétrico no tratamento de debilidades motoras, durante a última década esta área não estava integrada na rotina clínica diária. Desde então, com o amadurecimento e desenvolvimento dos meios técnicos para a análise clínica do sinal mioelétrico, novas pesquisas desenvolveram-se para explorar as potencialidades na aplicação da análise e reconhecimento do sinal mioelétrico no tratamento clínico de pacientes portadores de disfunções neuromusculares.

Com a evolução tecnológica, sistemas mais complexos vêm sendo apresentados ao longo dos anos, de modo a oferecer uma solução robusta para o problema de reconhecimento de padrões. Estudos propostos nas décadas de 60 e 70 careciam de meios técnicos para lidar

com o volume de processamento e capacidade de armazenamento de dados necessários para sua implementação. Na verdade, a tecnologia necessária para atender a demanda pela caracterização e classificação dos sinais mioelétricos é relativamente nova.

Em um estudo recente Staudenmann et al. [18] discute os problemas associados ao estudo do relacionamento entre a força muscular aplicada e o respectivo sinal mioelétrico gerado. O estudo enfatiza a importância da eletromiografia de superfície para trabalhos dessa natureza, uma vez que a opção a este método implica na utilização de eletrodos invasivos, que restringem as condições em que o experimento pode ser conduzido, além do já mencionado desconforto infligido pela utilização dessa técnica. Entender e estimar a relação força x sinal mioelétrico é fundamental, por exemplo, para estudar a carga suportada pelas articulações, uma vez que estas sofrem diretamente os efeitos do trabalho muscular. Frequentemente os fatores determinantes da força muscular são reduzidos ao termo “*ativação muscular*”, o que não constitui uma variável fisiológica, mas um modelo abstrato de entrada tempo-variável que escala o modelo de saída, cujo resultado é a força aplicada. Esta variável de entrada é convencionalmente estimada por meio da amplitude do sinal mioelétrico, que por sua vez normalmente é afetado por fatores tais como o tamanho da Unidade Motora acionada, a quantidade de Unidades Motoras recrutadas e pela taxa de disparo. Um sinal uni-dimensional, como a amplitude do sinal EMG, consegue fornecer apenas uma representação imprecisa desses três fatores. Outro fator pertinente, é que a amplitude do sinal EMG é afetada por fatores não relevantes para a produção de força muscular, tais como a forma da onda produzida pelos potenciais de ação das Unidades Motoras [18, 17].

A correta avaliação da força muscular deve considerar tanto uma informação espacial (Unidades Motoras acionadas) quanto uma informação temporal (a taxa de disparo das Unidades Motoras). Recentemente estudos mostram que informações adicionais fornecidas pela utilização de multi-canal EMG melhoraram a precisão na avaliação da força, baseada na análise do sinal mioelétrico. A direção da fibra muscular varia espacialmente com a movimentação do músculo, uma vez que a direção da propagação do potencial da Unidade Motora varia ao longo da direção da fibra, isso traz consequências quanto ao desalinhamento da fibra muscular e a utilização de sensores bipolares de superfície. Uma solução para este problema é a utilização de um número máximo possível de canais independentes sobre o músculo para aquisição do sinal mioelétrico. Uma vez que os sinais de

múltiplos canais distribuídos sobre um mesmo músculo não são necessariamente independentes, técnicas como a análise das componentes principais são utilizadas para remover informações redundantes do conjunto composto por sinais mioelétricos monopolares, potencializando a utilização da amplitude do sinal EMG como ferramenta para estimar a ativação do músculo [18].

Elias et. al [38] descreve a utilização do sinal eletromiográfico para a avaliação da relação entre a força de extensão do joelho e a atividade mioelétrica dos músculos componentes do quadríceps. Nesse experimento, cinco indivíduos entre 20 e 45 anos foram submetidos a exercícios isométricos controlados de extensão do joelho, com os sinais EMG capturados por um eletromiógrafo de 16 canais utilizando eletrodos bipolares como meio de captação dos sinais EMG. Uma célula de carga foi utilizada para medir a força produzida pelo movimento isométrico da perna, com o voluntário sentado e a perna posicionada formando um ângulo de 90 graus com o quadril. Os eletrodos foram posicionados sobre a pele, após tricotomia e assepsia com álcool 70%. Cada indivíduo realizou um movimento de extensão isométrica do joelho com três repetições, após o que o sinal registrado e armazenado forneceu um valor médio das três repetições, a partir das quais extraiu-se o valor RMS (*Root-Mean-Square*) do período total do movimento, equivalente a 5 segundos, fornecendo assim uma estimativa da energia do sinal EMG. Os valores obtidos foram normalizados pela CVSM (Contração Voluntária Submáxima), e relacionados com os valores médios da força empregada durante o período avaliado. Finalmente, o método dos mínimos quadrados foi utilizado para ajuste das curvas obtidas, com polinômio de ajuste fixado em dois, ou seja, $p(x) = a_1x^2 + a_2x + a_3$ [38].

O estudo concluiu que a estabilidade patelar é mais dependente dos componentes oblíquos do músculo quadríceps, sugerindo um padrão de recrutamento menor para o músculo reto-femoral, atribuída a sua constituição menor, e conseqüentemente da menor quantidade de fibras musculares presentes. O resultado admite também a possibilidade de a posição articular adotada para o experimento ter desfavorecido a contribuição deste músculo.

Mais importante do que os próprios resultados obtidos pelos experimentos descritos, é a evidência da viabilidade na utilização da eletromiografia de superfície como meio para o estudo e o desenvolvimento de pesquisas envolvendo o sinal mioelétrico. As diferentes técnicas aplicadas para o tratamento do sinal podem produzir resultados interessantes

quando aplicadas em conjunto. Esta pesquisa utiliza o conceito de assinatura do sinal mioelétrico e a análise multivariada de dados para obter resultados melhores na caracterização dos sinais EMG.

Novas linhas de pesquisa, que enfatizam o desenvolvimento de próteses ou de equipamentos controlados com o auxílio dos sinais EMG, vêm buscando melhorias, principalmente no que diz respeito à velocidade no processamento dos sinais registrados e na portabilidade dos equipamentos, itens que devem ser seriamente considerados quando se pretende viabilizar a utilização comercial de próteses e dispositivos de suporte a portadores de disfunções neuromusculares. Atualmente, técnicas sofisticadas utilizando Inteligência Artificial e modelos estatísticos são capazes de lidar com conjuntos de dados multidimensionais, tais como os sinais mioelétricos, estejam estes dados armazenados em um meio eletrônico ou alimentando diretamente um sistema de análise de sinais. A capacidade de tratar os sinais mioelétricos em tempo real, com maior ou menor grau de eficiência, já é uma realidade, graças ao contínuo avanço tecnológico que permite o desenvolvimento de dispositivos protéticos cada vez menores, mais leves e mais eficientes.

O fator determinante para o sucesso de um projeto cuja proposta seja interpretar corretamente e de maneira eficiente o sinal mioelétrico é a especificação precisa do seu objetivo. Sistemas destinados à análise clínica dos sinais, como os sistemas de apoio ao diagnóstico para pacientes portadores de disfunções musculares ou neurológicas, podem utilizar eletrodos invasivos, mais precisos e menos sujeitos a ruídos e variações elétricas, além de poder armazenar os sinais registrados para estudos e testes mais extensos. Por outro lado, a utilização do sinal mioelétrico para o desenvolvimento de membros artificiais e para o controle de dispositivos elétricos precisa, necessariamente, lidar com o movimento dinâmico e portanto com a necessidade de tratar este sinal em tempo real.

Pesquisas recentes utilizaram o sinal mioelétrico em aplicações com processamento em tempo real. Um estudo [45] dirigido pela universidade Jonh Hopkins, em Maryland, EUA, e financiado pelo exército americano, apresentou resultados em 2001 descrevendo uma técnica denominada reinervação dirigida de músculos, na qual os nervos remanescentes em um braço amputado são conectados a outros músculos, muitas vezes aos músculos do peito. Esta técnica permite melhorar a qualidade do sinal mioelétrico disponível para o controle do braço mecânico, uma vez que utiliza a musculatura inervada como potencializador do sinal, melhorando a captação dos sinais pelos eletrodos de superfície localizados na

prótese. Segundo os pesquisadores, isto permite ao paciente um controle muito maior sobre a prótese, permitindo dez tipos de movimento de mão, pulso e cotovelo e com movimentos simultâneos, o que aumenta a velocidade dos movimentos efetuados, exigindo não mais do que o esforço consciente necessário a uma pessoa com um braço natural [45]. A técnica também tem suas limitações, sendo ainda cara e necessitando de um longo tempo de adaptação para que os nervos reconectados tornem-se eficientes novamente.

O desenvolvimento de materiais muito leves e extremamente resistentes, a nanotecnologia e a bioengenharia, têm permitido aos pesquisadores desenhar um futuro difícil de conceber a meros 10 anos atrás. O estudo e a decodificação dos sinais eletroencefalográficos, ou a eletroneuromiografia, permitem hoje a realização de experimentos que parecem fruto da telepatia, com pensamentos específicos traduzidos por softwares complexos.

Pesquisas que utilizam o sinal eletroencefalográfico, ou EEGs, para o controle de membros artificiais e dispositivos de interface homem-máquina ou interfaces brain-machine (BMIs - *Brain Machine Interfaces*) também já são uma realidade.

Na Universidade Duke, NC, USA, os pesquisadores M. A. L. Nicolelis e M. A. Lebedev conduziram experimentos envolvendo os sinais EEG, nos quais utilizaram eletrodos invasivos, em função da qualidade do sinal eletroencefalográfico ser muito inferior ao EMG, quando este é captado por eletrodos superficiais [42]. Esta técnica entretanto possui riscos inerentes ao procedimento cirúrgico para implantação dos eletrodos diretamente no tecido cerebral. Nicolelis et al. [41] descreve o experimento no qual primatas são submetidos a um implante cerebral que capta os sinais EEG, permitindo compreender como determinados neurônios estão envolvidos no processo motor destes animais, com o objetivo de desenvolver neuropróteses, capazes de auxiliar na reabilitação de pacientes com paralisia.

A busca constante por um modelo que permita equacionar o problema *desempenho VS confiabilidade e portabilidade*, impulsionou o desenvolvimento de diferentes técnicas, implementadas para as etapas de processamento e reconhecimento dos sinais mioelétricos. Embora seja possível identificar características comuns nas arquiteturas apresentadas em muitos dos trabalhos recentes, um modelo se destaca em função da boa relação *desempenho VS confiabilidade*. O fluxograma da figura 2.7 ilustra o diagrama de um sistema típico para classificação de sinais multidimensionais, tais como os sinais mioelétricos.

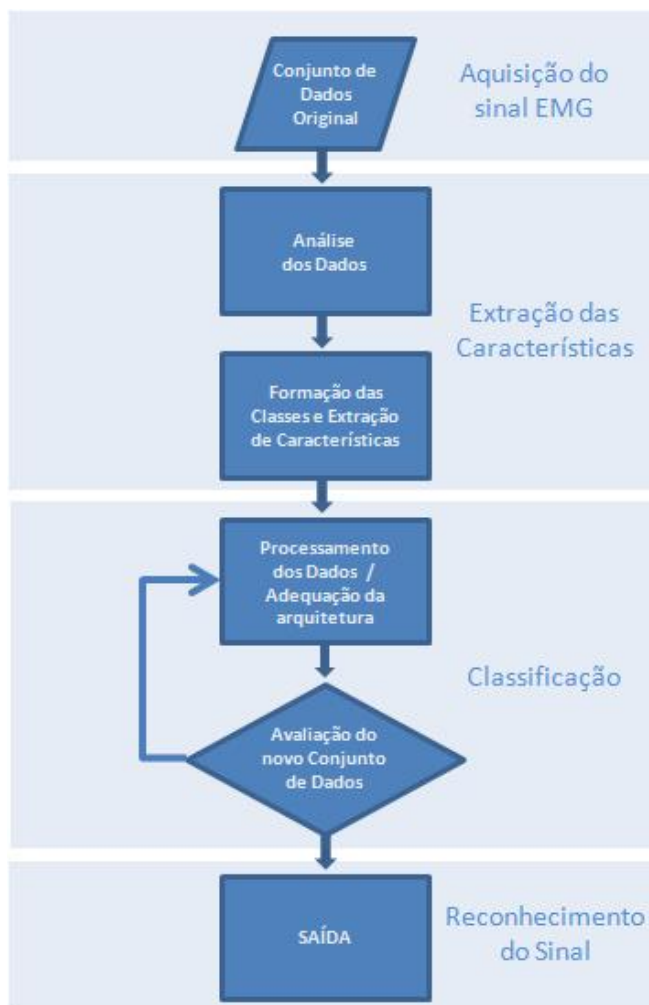


Figura 2.7: Arcabouço típico utilizado para o reconhecimento e classificação de sinais EMG, com as etapas de aquisição do sinal mioelétrico, a extração das características, a classificação e o reconhecimento do sinal mioelétrico.

Esta abordagem segue uma tendência recente, cada vez mais presente nos estudos envolvendo o sinal mioelétrico, ao utilizar técnicas estatísticas em conjunto com técnicas baseadas em Inteligência Artificial, com o objetivo de melhorar a taxa de reconhecimento do classificador, e de reduzir o tempo de processamento do sistema, melhorando seu desempenho.

Este tipo de arcabouço aparece em diversos trabalhos [48, 46, 21, 9, 5, 8, 51, 57, 52, 35, 20, 40] realizados e publicados ao longo dos últimos 15 anos. Uma rede neural, capaz de reconhecer o sinal mioelétrico com acuidade, foi proposta por Del e Park [5] em 1994 utilizando este modelo, onde as características dos sinais mioelétricos são primeiramente extraídas através de uma análise de Fourier e separadas usando um algoritmo baseado em Lógica Fuzzy denominado FCM (ou melhor, *Fuzzy C-Means*). Este método de clus-

terização, baseado em FCM, permite que os dados pertençam a dois ou mais clusters simultaneamente. A saída da rede neural representa o grau de estímulo muscular desejado. Para o aprendizado da rede, foi proposta a utilização do método *back propagation* [53, 1], considerando uma rede neural multi-camada. Através deste procedimento, a rede pode mapear um conjunto de entradas em função de um conjunto de saídas. Segundo os autores [5], a operação em tempo real poderia ser conseguida em função da utilização de processadores de sinal digital para executar a transformada de Fourier e extrair as características do sinal para posterior classificação. A topologia escolhida para essa rede foi a *feedforward*, com uma camada de entrada contendo 64 neurônios, uma camada escondida com dois neurônios e um neurônio de saída.

Outra proposta baseada na interpretação do sinal mioelétrico para o controle de uma prótese multifuncional foi feita por Hudgins et al. [8], em 1993. Nesta abordagem, quatro voluntários com membros normais e um amputado acima do cotovelo fizeram parte de um estudo no qual dados mioelétricos foram registrados de cada indivíduo, durante contrações isométricas e não isométricas. O sinal foi registrado utilizando-se um par de eletrodos bipolares de superfície, posicionados sobre o bíceps e o tríceps de cada indivíduo. Devido à natureza do sinal mioelétrico, era esperada uma grande variação no valor de determinadas características entre indivíduos. Outros fatores, tais como mudanças na posição dos eletrodos e flutuações no peso corporal deveriam provocar variações em função do tempo. Como no modelo proposto por Del e Park [5], novamente uma rede neural artificial foi escolhida como classificador para esta aplicação. A estrutura básica utilizada foi uma rede padrão em duas camadas, utilizando o algoritmo *back propagation*. Hudgins não conseguiu determinar um número ideal para os neurônios na camada escondida da rede e argumentou que este ajuste parece variar em função do problema. O tempo para treinar a rede, bem como a avaliação do desempenho do sistema, face ao tempo necessário para processar os dados de entrada, não fizeram parte do escopo deste experimento. Entretanto, o reconhecimento do padrão no sinal mioelétrico foi bem sucedido.

Mais recentemente, Nazarpour et al. [35] apresentou uma proposta para o reconhecimento e classificação dos sinais mioelétricos que também se encaixa no arcabouço ilustrado na figura 2.7. Nos experimentos descritos, o registro do sinal mioelétrico foi feito a partir do bíceps e do tríceps de um voluntário, utilizando-se dois pares de eletrodos. Os eletrodos ficaram afastados a uma distância de 20mm. O sinal EMG foi amplificado e um filtro

passa-banda foi aplicado. Um filtro rejeita 50 Hz foi aplicado ao sinal detectado. A taxa de frequência foi ajustada em 1000 Hz. As classes foram formadas a partir das contrações efetuadas pelo voluntário, classificadas como alta, média e baixa. A partir daí, registros contínuos foram feitos para ambos os músculos, com duração de 5 segundos. Cada registro foi subdividido em segmentos de 200 ms, produzindo 25 séries por contração. O voluntário executou os experimentos 3 vezes para cada nível de contração.

Para a classificação dos padrões, Nazarpour et al. [35] utilizou uma rede perceptron de 3 camadas com 30 neurônios na camada de entrada, 20 neurônios na camada escondida e 4 neurônios na camada de saída. Analogamente ao experimento proposto por Hudgins [8], o número de neurônios na camada escondida foi determinado experimentalmente, na tentativa de obter níveis aceitáveis de classificações corretas. Os pesos foram ajustados durante o período de aprendizagem, utilizando o método do gradiente descendente e o algoritmo *back propagation*. O experimento utilizou ainda a análise das componentes principais (PCA) [33] para normalizar o conjunto de entrada e avaliar a taxa de reconhecimento do sinal EMG obtida antes e após a sua utilização.

A utilização de redes neurais como ferramenta para a classificação de dados está presente em diversas pesquisas que procuram caracterizar ou classificar o sinal mioelétrico. Existem pesquisas que tentam, por exemplo, prever a quantidade de força necessária para a ativação de uma prótese ou de uma ferramenta biomecânica. Changmok Choi [9] utilizou uma rede neural para o controle de uma mão mecânica durante o movimento de pressão, sem entretanto utilizar sensores de pressão. Uma vez que a amplitude do sinal mioelétrico guarda uma correlação com a força gerada pelo músculo [49], é possível determinar, por meio da análise do sinal, a força aplicada a uma mão mecânica durante a ação de segurar um determinado objeto. Esta pesquisa ilustra como a utilização dos sinais mioelétricos pode abrir portas para as mais diversas aplicações, envolvendo uma resposta sensora em dispositivos biomecânicos ou membros artificiais, utilizando os biopotenciais como um instrumento natural de interpretação do meio. Em seu experimento, Choi utilizou uma rede neural artificial, inspirada em redes neurais biológicas, e composta por um número de neurônios artificiais altamente interligados, ativados por um estímulo externo. O autor menciona o fato de uma rede neural funcionar como uma “caixa-preta”, como uma das principais vantagens ao se utilizar este modelo, isto porque dessa forma, o pesquisador não precisa lidar com informações detalhadas específicas, tais como a relação que existe

entre o sinal EMG e a variação da força aplicada ao músculo. Isto acontece porque as redes neurais são capazes de lidar com uma classe abrangente de fenômenos naturais e artificiais, que seriam difíceis de caracterizar e tratar por meio de técnicas paramétricas clássicas. A rede neural trata de ajustar-se até que se estabilize em um estado no qual os valores de saída sejam considerados satisfatórios [9].

Entretanto, sabe-se que esta característica das redes neurais constitui um dos principais problemas no que se refere à sua utilização para o estudo de conjuntos massivos de dados. É um fato conhecido que o comportamento tipo “caixa-preta” impede a completa compreensão do que acontece com os dados durante seu processo de caracterização e classificação, dificultando o completo entendimento do fenômeno estudado.

Em [9], o autor reconhece as limitações e dificuldades impostas pela utilização de uma rede neural, ainda que a taxa de reconhecimento do sinal mioelétrico e sua classificação tenham sido bem sucedidos. Choi explica que o desempenho do sistema depende, em grande parte, da necessidade de se determinar a estrutura da rede com um grau de liberdade ou informação que sejam coerentes com o conjunto de treinamento. A estrutura da rede pode conter várias camadas escondidas, ainda que uma camada seja, em teoria, suficiente para a convergência dos dados, de acordo com o Teorema de Aproximação Universal [9, 53]. O teorema, por outro lado, não especifica a quantidade de neurônios na camada escondida, o que torna necessário determinar este parâmetro empiricamente. Este número deveria ser estimado considerando-se o grau de não-linearidades entre as amostras na entrada da rede e os dados gerados na saída, entretanto, é uma tarefa difícil definir não-linearidades entre o sinal EMG e nível de força aplicado pelo músculo.

Além dos modelos de reconhecimento de padrões baseados em redes neurais, sistemas baseados em Lógica Fuzzy também são propostos na literatura para o processamento e classificação dos sinais biométricos, pois têm como característica a capacidade de lidar com dados contraditórios. Sinais como os EMG não são necessariamente repetíveis, e podem ser contraditórios em função tanto dos ruídos presentes nos sinais registrados quanto das diferenças morfológicas que existem de um para outro indivíduo, e em função das características estruturais e funcionais das fibras musculares [32]. Devido ao sistema Fuzzy de processamento assemelhar-se ao modo como o ser humano pondera os problemas, existe ainda a possibilidade de integrar o conhecimento de médicos especialistas ao sistema, o que traz uma vantagem comparativa em relação aos sistemas que utilizam redes neurais.

Além disso, a utilização de sistemas baseados em Lógica Fuzzy possibilita a descoberta de padrões nos dados que não seriam facilmente detectados por outros meios [44]. Estes padrões entretanto não necessariamente serão essenciais para melhorar o entendimento do conjunto de dados original, ou mesmo para produzir um resultado ótimo na etapa de classificação dos sinais.

Em 1999, um estudo propondo uma abordagem híbrida foi descrito por Micera et al. [52], aplicando técnicas estatísticas e lógica fuzzy para a classificação e análise dos sinais EMG, provenientes dos movimentos do braço. O trabalho, intitulado “*A hybrid approach to EMG pattern analysis for classification of arm movements using statistical and fuzzy technics*”, chama a atenção para a natureza estocástica do sinal EMG puro, e para a necessidade da seleção correta das características que deseja-se extrair deste conjunto de dados, bem como a especificação da estrutura do classificador que será utilizado. No estudo apresentado, os autores lembram que a taxa estimada do erro de um determinado classificador é utilizada para medir sua robustez e sua capacidade de discriminação. Esta abordagem enfatiza a importância de selecionar a combinação apropriada de características que determinarão a qualidade da classificação, independentemente da técnica empregada. Por outro lado, outros pesquisadores assumem que as características do sinal mioelétrico podem ser especificadas, liberando-os para a tarefa de identificar classificadores eficientes [52].

Micera et al. [52] afirmam que optar por utilizar uma arquitetura fixa para a rede neural artificial geralmente apresenta um problema para determinar o tamanho do conjunto de dados necessário para que se obtenha uma boa generalização da solução. Por outro lado, quando o tamanho do conjunto de treinamento é fixado, é necessário identificar-se uma arquitetura adequada para a classificação. Para lidar com estas limitações, os autores propõem um modelo de classificador baseado em um sistema fuzzy, caracterizado por uma arquitetura de aprendizagem supervisionada, com boa generalização, aprendizagem rápida e baixo custo computacional [52]. Este experimento avaliou o sinal mioelétrico em seis voluntários, registrado de uma seleção de sete músculos, localizados próximos, a saber: trapézio superior, trapézio medial e trapézio inferior, deltoide anterior, medial e anterior e músculo peitoral maior [52].

Segundo os autores, esta abordagem permitiu a identificação dos movimentos sagital, ipsilateral e contralateral do membro superior, através da análise do sinal EMG obtido a

partir dos músculos do ombro, com importantes vantagens sobre outros métodos, a saber:

- O sistema foi capaz de determinar automaticamente, para cada um dos indivíduos, os músculos com maior relevância no que diz respeito a informação para o processo de classificação, sem a supervisão humana;
- O início do movimento é determinado utilizando-se um ajuste, devidamente selecionado afim de minimizar a taxa de falso-alarme para uma determinada detecção de latência;
- O processo de extração de características do conjunto de dados é compatível com aplicações próximas do tempo real;
- O processo de classificação do movimento é baseado em um sistema fuzzy, cuja estrutura é extraída diretamente de dados numéricos.

Segundo os autores [52], a taxa de reconhecimento dos movimentos envolvidos neste experimento foi boa, apesar do fato de que o conjunto de treinamento foi pequeno. A validade do experimento deverá ser corroborada por estudos mais aprofundados.

Muitos estudos aplicaram técnicas similares para a classificação do sinal EMG, porém para a fase de extração das características do sinal mioelétrico alguns trabalhos apresentaram um procedimento mais simples. Vuskovic et al. [40] descreve em seu trabalho, *Classification of Prehensile EMG Patterns With Simplified Fuzzy ARTMAP Networks*, um método de extração de características simplificado, baseado em *Hammimg windowing*. Este trabalho propõe o reconhecimento e classificação do sinal mioelétrico através de uma rede fuzzy ARTMAP modificada. Este estudo considerou um modelo de controle para uma mão artificial que não estivesse limitada à solução habitual de um movimento em garra, que possui apenas 1 grau de liberdade (GDL). Segundo Arieta et al. [6], uma mão natural é composta por 5 dedos, pela palma e pela junta do pulso. Cada dedo possuindo 4 graus de liberdade. A palma da mão possui muitas articulações, mas o movimento está integrado em apenas 1 grau de liberdade. O pulso possui 3 graus de liberdade, totalizando 24 GDL para uma mão. Vuskovic et al. [40] descreve em um estudo preliminar, para o qual foi utilizado, com sucesso, um classificador estatístico para a extração de características do conjunto de dados, aplicado a 4 eletrodos de superfície para sinais mioelétricos. Neste estudo, o comprimento das amostras dos sinais EMG ficou entre 300 e 400 milissegundos, mas esta taxa foi considerada muito alta para uma aplicação em tempo real.

Para as condições propostas, o comprimento das amostras deveria ser de no máximo 200 milissegundos, para possibilitar a extração de características e a classificação dos dados.

Entretanto, o controle de uma mão que possuísse diversos graus de liberdade, exigiria uma abordagem mais elaborada para as tarefas de extração e classificação dos dados. Uma rede neural *back propagation* em duas camadas foi utilizada, porém sem muito sucesso devido à quantidade necessária de treinamento de padrões, pois o tempo para a convergência do processo de treinamento era muito longo, enquanto a taxa de reconhecimento não obtinha uma melhora significativa. Além disso, as redes *back propagation* não apresentaram uma boa resposta para o aprendizado incremental, fundamental para este tipo de aplicação. Para solucionar o problema, os autores utilizaram uma rede Fuzzy ARTMAP Simplificada, com pequenas alterações [40].

2.6 Considerações Adicionais

A aplicação de técnicas estatísticas em conjunto com Redes Neurais e Lógica Fuzzy vem contribuindo para o constante desenvolvimento no reconhecimento do sinal mioelétrico. Entretanto, a utilização de modelos estatísticos como ferramenta principal para o reconhecimento destes sinais ainda é um tema pouco explorado. A utilização da análise das componentes principais, ou PCA, para o estudo e aplicação clínica da biomecânica só recentemente vem sendo considerado. Torna-se evidente, face às pesquisas desenvolvidas para o estudo do movimento humano, que a complexidade da sua descrição deriva, em grande parte, do número de variáveis envolvidas em seu mecanismo, e não apenas das características e particularidades que envolvem o sinal mioelétrico.

Atualmente, sistemas baseados em redes neurais ainda não apresentam um bom desempenho para processamento online, em função do tempo necessário para treinar a rede, do alto volume de variáveis de entrada, inerentes ao sinal EMG, e da falta de parâmetro ou heurística definida no momento de especificar a topologia da rede, além da complexidade computacional para a implementação deste modelo com poucas amostras. A Lógica Fuzzy, apesar de possibilitar agregar o conhecimento humano ao sistema, e de reduzir a necessidade de regras para avaliação dos dados de entrada, também precisa lidar com um volume alto de variáveis de entrada. Sua eficiência para lidar de forma robusta com sinais mioelétricos, contudo, não pôde ser verificada.

Entretanto, pesquisas utilizando sistemas híbridos apresentaram um melhor desempe-

nho [40, 21, 52] aplicando técnicas estatísticas que possibilitaram a redução do conjunto de dados, para que estes pudessem ser mais facilmente manipulados através de Redes Neurais ou de modelos utilizando Lógica Fuzzy. A utilização de técnicas estatísticas avançadas, não somente na etapa de pré-processamento dos dados mas na sua classificação propriamente, aponta para uma melhoria significativa no tempo de resposta e na aplicabilidade comercial para sistemas de análise do sinal EMG, sendo esta a principal abordagem utilizada como metodologia para este trabalho.

Capítulo 3

Métodos de Análise Multivariada

3.1 Análise Multivariada

Dados multivariados ou multidimensionais são aqueles compostos por múltiplas medições, observações ou respostas, obtidas em uma coleção de variáveis selecionadas ou aleatórias, podendo ser formadas por valores numéricos, textos ou imagens e geralmente constituindo um conjunto de dados brutos [7].

A análise estatística multivariada é a análise estatística simultânea desses dados multivariados, possibilitando o estudo da relação entre as variáveis que compõem estes conjuntos. Segundo Izenman(2008)[7], muito da motivação inicial para o estudo e desenvolvimento da análise multivariada teve sua origem na necessidade de solucionar problemas apresentados pelas ciências social e comportamental, especialmente nas áreas da educação e da psicologia. Assim, a análise fatorial foi concebida para fornecer um modelo estatístico que pudesse explicar teorias da psicologia sobre a habilidade e o comportamento humanos; o escalonamento multidimensional teve suas origens devido a necessidade da psicometria entender o julgamento das pessoas quanto à similaridade de itens dentro de um determinado conjunto; a análise das componentes principais, por sua vez, teve como um dos fatores que motivaram seu desenvolvimento o estudo para analisar a pontuação alcançada por estudantes em uma bateria de diferentes testes; a variável canônica e a análise de correlação tiveram uma origem similar das componentes principais, porém o objeto de interesse nesse caso era a pontuação obtida por grupos de estudantes em duas baterias separadas de testes[7].

Outros métodos de análise multivariada foram motivados por problemas em outras áreas científicas. A análise discriminante linear surgiu para resolver um problema de clas-

sificação na área da botânica que envolvia múltiplas medições; a análise da variância, e a análise multivariada da variância surgiram da necessidade de analisar dados envolvendo experimentos agrícolas; as origens da regressão e da correlação têm haver com problemas envolvendo hereditariedade e as órbitas dos planetas[7]. De modo geral, as técnicas mencionadas foram criadas para solucionar problemas sociais e científicos em uma época em que os conjuntos de dados envolvidos tinham dimensões muito inferiores aos que se apresentam atualmente, e eram manipulados por computadores com uma fração do poder computacional disponível nos dias de hoje.

O rápido desenvolvimento computacional que vivenciamos hoje permite o armazenamento massivo de informações, possibilitando lidar com problemas cada vez mais complexos. Dessa forma, as técnicas de análise multivariada tornaram-se extremamente atuais, apesar de terem suas origens datadas já há mais de cem anos, pois agora é possível lidar com espaços dimensionais muito maiores que aqueles considerados à época em que essas ferramentas foram concebidas.

Os sinais mioelétricos são conjuntos de dados multivariados, caracteristicamente compostos por centenas ou milhares de variáveis, dependendo da taxa de amostragem utilizada durante sua aquisição e registro, com espaços que chegam facilmente a 10^4 ou 10^5 dimensões, com valores randômicos e muitas vezes redundantes [16].

Um sinal mioelétrico composto de n variáveis pode ser tratado como um ponto em um espaço n dimensional, chamado de espaço original. Esse ponto é representado pelas variáveis que compõem o sinal e formam um vetor altamente dimensional tal que $x^T = [x_1, x_2, \dots, x_n]$, com $n \gg 1$. Dada uma situação onde é necessário tratar um determinado conjunto de dados n -dimensional e redundante, consideramos a possibilidade de projetar estes dados multivariados em um espaço de dimensão menor, sem que haja perda significativa de informação. Esta redução de dimensionalidade pode ser alcançada através da seleção das variáveis de interesse dentro deste conjunto de dados, método conhecido como *seleção de características*. Outra forma de conseguir esta redução, é através da transformação linear ou não linear das variáveis de entrada, projetando-as em um conjunto de dimensionalidade menor, método conhecido como *extração de características* [23, 7].

Este capítulo descreve as técnicas de estatística multivariada utilizadas neste trabalho para analisar e caracterizar os sinais mioelétricos através de transformações lineares e não

lineares.

3.2 Análise das Componentes Principais

3.2.1 Introdução e Breve Histórico



Figura 3.1: Karl Pearson.

Em 1901 o matemático Karl Pearson, representado na figura 3.1¹, então professor da *University College of London*, imaginou e descreveu uma solução, através de um procedimento geométrico, para a transformação de um vetor n -dimensional por meio de m vetores linearmente independentes [26, 2]. Este método era a Análise de Componentes Principais, ou simplesmente PCA (*Principal Components Analysis*). Pearson tentava, nesta época, explicar eventos biométricos e moto-relacionados, porém não descreveu um método prático de cálculo do PCA que considerasse o uso de muitas variáveis. Foi apenas mais tarde, em 1933, que o também matemático e estatístico Harold Hotteling, professor da Universidade de Stanford, descreveu um método capaz de lidar com um grande número de variáveis, fato pelo qual o PCA é também conhecido como transformada de Hotteling. Esta tarefa entretanto ainda era penosa, considerando o volume de dados e cálculos envolvidos. Foi apenas mais recentemente, com o advento da moderna computação, que esta técnica tornou-se difundida [10].

O PCA é um método estatístico multivariado utilizado para reduzir a dimensionalidade de um determinado conjunto de dados n -dimensional, através da eliminação das

¹Fonte: www.upload.wikimedia.org/wikipedia/commons/1/18/Karl_Pearson_1912.jpg. Acesso 27/04/2010.

variáveis redundantes, permitindo identificar padrões existentes entre os dados que compõem este conjunto, destacando suas características principais enquanto mantém o máximo possível da variação presente na informação original. Sua utilização se estende desde sistemas de apoio a neurociência até a computação gráfica, pois trata-se de um método não-supervisionado simples para extração de informação útil, a partir de conjuntos de dados complexos [27, 4].

Determinados conjuntos de dados, tais como aqueles provenientes de sinais como o mioelétrico, geralmente possuem dados altamente redundantes. O PCA opera extraíndo características destes conjuntos de dados através do seu descorrelacionamento, eliminando parte da informação redundante enquanto reduz sua dimensionalidade, sem que haja uma perda significativa de informação, pois, considerando sistemas redundantes, é comum explicar mais do que 90% da variância total das amostras nas primeiras componentes principais. Esta técnica essencialmente re-escreve as coordenadas das amostras, facilitando a interpretação dos dados através de combinações lineares, gerando m componentes principais, a partir de n variáveis originais, obtidas em ordem decrescente de máxima variância [30].

3.2.2 Cálculo das Componentes Principais

Segundo Fukunaga [33], quando um vetor x n -dimensional é transformado linearmente em outro vetor m -dimensional y , este é representado algebricamente como uma função de x , ou seja,

$$y = Px, \quad (3.1)$$

onde P é uma matriz de dimensão $n \times m$. Matematicamente, o PCA transforma, por meio de combinações lineares, um determinado vetor $x \in \mathfrak{R}^n$ em outro vetor $y \in \mathfrak{R}^m$ tal que $m \leq n$, projetando x em m direções ortogonais de maior variância, que são suas componentes principais.

Mais detalhadamente, sejam os vetores $x_1^T = \{x_{11}, x_{12}, \dots, x_{1n}\}$, $x_2^T = \{x_{21}, x_{22}, \dots, x_{2n}\}$, ..., e $x_N^T = \{x_{N1}, x_{N2}, \dots, x_{Nn}\}$, amostras de sinais mioelétricos de dimensão n , formando uma matriz X de dados $N \times n$, onde cada um desses vetores representa uma linha desta matriz. Deseja-se representar estes vetores em função das componentes principais, ou seja, como um ponto no espaço \mathfrak{R}^m . O PCA calcula então a matriz de covariância S desses

dados através da seguinte equação:

$$S = \frac{1}{(N-1)} \sum_{i=1}^N (x_i - \bar{x})(x_i - \bar{x})^T, \quad (3.2)$$

onde N é o número total de amostras e \bar{x} o vetor média de todas as amostras, isto é:

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i. \quad (3.3)$$

O próximo passo é calcular os autovetores e autovalores de S . Seja $x \in \mathfrak{R}^n$ um vetor não-nulo. Este vetor x será um autovetor da matriz S se satisfizer a equação $Sx = \lambda x$, para algum valor de λ . A solução para este problema consiste em calcular o termo determinante da matriz $(S - \lambda I)$ e igualá-lo a zero, ou seja,

$$\det(S - \lambda I) = 0. \quad (3.4)$$

A equação (3.4) é chamada de *equação característica* e, quando expandida, produz um polinômio de grau n em λ com n raízes reais ou complexas $(\lambda_1, \lambda_2, \dots, \lambda_n)$, de tal forma que para cada valor λ_i existe um autovetor ϕ_i correspondente [3, 19, 24].

Embora autovalores sejam em geral representados por números complexos, os autovalores da matriz S são números reais, pois S é uma matriz real e simétrica [31]. Este é um resultado fundamental e importante para utilização de matrizes de covariância em análises estatísticas multivariadas, pois não somente os autovetores existem como também existe um conjunto completo de m autovetores ϕ_i com seus respectivos autovalores λ_i representados por valores reais [11], onde $m \leq n$. Em outras palavras, existe uma matriz ortogonal Φ_{pca} de dimensão $n \times m$ cujas colunas são os autovetores da matriz de covariância S e também uma matriz diagonal Λ_{pca} de dimensão $m \times m$ cujos elementos da diagonal são os autovalores de S , tal que:

$$\Phi_{pca}^T S \Phi_{pca} = \Lambda_{pca}. \quad (3.5)$$

Neste ponto, os autovalores da matriz de covariância já trazem informações sobre os padrões contidos no conjunto de dados, mas ainda são dados n -dimensionais. Para que seja possível extrair informações realmente úteis em conjuntos de dados altamente dimensionais, estes precisam ser representados em uma dimensão menor. Os m autovetores, calculados nos passos anteriores, são o parâmetro para a definição da quantidade de di-

mensões necessárias para representar o conjunto de dados, e são ordenados do maior para o menor autovalor. Os primeiros autovetores são as componentes principais do conjunto de dados e, normalmente, as 2 ou 3 primeiras componentes ($m = 2$ ou $m = 3$) retêm a maior parte da informação.

Portanto, o último passo para representar o conjunto de dados original X no espaço das componentes principais se dá pela multiplicação dessa matriz de dados pela matriz Φ_{pca} , ou seja:

$$Y = X\Phi_{pca}. \quad (3.6)$$

Isso nos deixa com uma nova representação Y do conjunto de dados original X , agora em função das direções representadas pelas componentes principais, e não mais em função dos eixos originais. A representação gráfica deste novo conjunto pode ser feita em função dos autovetores com maiores autovalores, revelando agora os dados descorrelacionados, selecionados como uma combinação linear que leva em conta sua relação com os demais dados do conjunto original.

3.2.3 Geometria das Componentes Principais

Algebricamente, as componentes principais são transformações lineares de n variáveis aleatórias. Geometricamente, essa transformação linear equivale a uma rotação nos eixos definidos pelas variáveis originais. Essa rotação será efetuada sucessivas vezes, até que sejam selecionadas as direções que representem a maior variabilidade dos dados originais, descorrelacionando-os e fornecendo uma descrição mais simples da estrutura de covariância para o conjunto de variáveis em análise [10, 54].

Para explicar o que foi dito no parágrafo acima, deve-se lembrar que o PCA lida com uma única amostra de N vetores de observação x_1, x_2, \dots, x_n , em uma população X com $X \approx N_n(\mu, \Sigma)$, que formam um espalhamento de pontos em um espaço n -dimensional. É importante salientar que a análise das componentes principais pode ser aplicada a qualquer distribuição de x , mas considerar um espalhamento elipsoidal para estes pontos, facilita a visualização da geometria envolvida nos cálculos do PCA. Deseja-se então encontrar os eixos naturais de espalhamento dos pontos da elipsoide com origem em \bar{x} .

Então, as amostras das componentes principais, $\hat{y}_i = \hat{e}'_i(x - \bar{x})$ retiradas da população de componentes $Y_i = e'_i$, possuem uma distribuição $N_n(0, \Lambda)$. A matriz diagonal Λ é

formada pelos elementos $\lambda_1, \lambda_2, \dots, \lambda_m$, com os pares de auto-valor e auto-vetor (λ_i, e_i) da matriz de covariância Σ . Pelas amostras de x_j , pode-se aproximar μ por \bar{x} e Σ por S . Caso a matriz S seja positiva, ou seja, se for inversível e possuir todos os valores maiores que zero, o contorno consistindo de todos os valores n -dimensionais de x que satisfazem

$$(x - \bar{x})' S^{-1} (x - \bar{x}) = c^2, \quad (3.7)$$

estimam o contorno de densidade da população X . O contorno aproximado pode ser desenhado em um gráfico para indicar a distribuição que gerou os dados. Geometricamente, os dados podem ser apresentados como n -pontos em um espaço m -dimensional. Esses dados podem então ser expressos em novas coordenadas, que coincidem com os eixos de contorno da elipsoide descrita pela equação 3.7. Esta hiper-elipsoide, uma vez que representa um espaço hiper-dimensional, é centrada em \bar{x} , e seus eixos agora são dados pelos autovetores de S , uma vez que S é simétrica e positiva. Os comprimentos dos eixos da hiper-elipsoide são proporcionais a $\sqrt{\hat{\lambda}_i}$, com $i = 1, 2, \dots, m$, onde $\hat{\lambda}_1 \geq \hat{\lambda}_2 \geq \dots \geq \hat{\lambda}_m \geq 0$ são os autovalores de S .

Como o autovetor normalizado \hat{e}_i tem comprimento 1, o valor absoluto da i -ésima componente principal, expressa em $|\hat{\lambda}_i| = |\hat{e}_i'(x - \bar{x})|$ corresponde ao comprimento da projeção do vetor $(x - \bar{x})$ sobre o vetor unitário \hat{e}_i . Dessa forma, as componentes principais $\hat{y}_i = \hat{e}_i'(x - \hat{x})$, $i = 1, 2, \dots, m$, recaem sobre os eixos da hiper-elipsoide, e seus valores absolutos correspondem aos comprimentos das projeções de $x - \hat{x}$ nas direções dos eixos \hat{e}_i . Assim, as componentes principais podem ser vistas como o resultado da translação da origem do sistema de coordenadas original para \bar{x} e a subsequente rotação dos eixos coordenados até que estes se alinhem com as direções de máxima variância dos dados. As Figuras 3.2(a) e 3.2(b) ilustram essa interpretação geométrica das componentes principais.




Figura 3.2: Ilustração da interpretação geométrica das componentes principais com dois exemplos de distribuição dos dados, uma (a) com variância significativa descrevendo um espalhamento elipsoidal, onde as componentes principais descrevem os eixos de maior variância dos dados, e outra (b) com uma variância homogênea dos dados, impossibilitando uma boa representação do conjunto em uma dimensão menor que a original. Fonte: adaptado de [54].

A figura 3.2(a) ilustra uma elipse de distância constante e centrada em \bar{x} , com $\hat{\lambda}_1 > \hat{\lambda}_2$. As componentes principais estão bem determinadas, recaindo ao longo dos eixos da elipse que descrevem a máxima variância dos dados amostrados. A figura 3.2(b) ilustra uma elipse com distância constante, centrada em \bar{x} e com $\hat{\lambda}_1 = \hat{\lambda}_2$. Se ocorre $\hat{\lambda}_1 = \hat{\lambda}_2$ então os eixos da elipse de distância constante, que o exemplo da figura 3.2(b) descreve com um círculo, não são únicos, e podem recair sobre quaisquer duas direções perpendiculares, incluindo as direções que descreviam as coordenadas dos eixos originais. Assim, quando o contorno da distância constante é aproximadamente circular, ou de modo análogo, quando os autovalores de S são aproximadamente iguais, a variância dos dados é homogênea em todas as direções. Neste caso não é possível uma boa representação do conjunto de dados em uma dimensão menor que a original.

Finalmente, se os últimos autovalores $\hat{\lambda}_i$ forem tão pequenos que sua variância nas \hat{e}_i direções correspondentes sejam desprezíveis, as componentes principais correspondentes poderão então ser ignoradas, sem que haja perda significativa no conjunto de dados original.

Kernel Principal Component Analysis

A análise do kernel das componentes principais, ou simplesmente KPCA, é um método multivariado não linear de análise de dados, originalmente desenvolvido por *Schölkopf et al.* em 1998[29], e apresentado como uma generalização não linear do PCA. O algoritmo

para o cálculo do KPCA é similar ao algoritmo do PCA, mapeando as variáveis do conjunto de dados original X em um espaço amostral \mathfrak{S} , através da uma função ϕ [28], como ilustra a Figura 3.3.




Figura 3.3: Demonstração do KPCA onde os dados originais, inicialmente representados em uma espaço não linear, são mapeados linearmente em um novo espaço amostral. Fonte: adaptado de [28]).

Seja então a função não-linear ϕ que mapeia o espaço amostral de entrada \mathfrak{R}^n no espaço \mathfrak{S} [13],

$$\phi : x \in \mathfrak{R}^n \rightarrow \phi(x) \in \mathfrak{S}. \quad (3.8)$$

Como resultado, um padrão no espaço original entrada \mathfrak{R}^n é mapeado em um vetor de dimensão potencialmente maior em \mathfrak{S} . Dado um conjunto de N amostras x_1, x_2, \dots, x_N em \mathfrak{R}^n , a matriz de covariância no espaço \mathfrak{S} pode ser dada por

$$\tilde{S} = \frac{1}{(N-1)} \sum_{i=1}^N (\phi(x_i) - \bar{\phi})(\phi(x_i) - \bar{\phi})^T, \quad (3.9)$$

onde $\bar{\phi}$ é o vetor médio de todas as amostras mapeadas no espaço característico[13], tal que

$$\bar{\phi} = \frac{1}{N} \sum_{i=1}^N \phi(x_i). \quad (3.10)$$

Uma vez que todo autovalor de um autovetor positivo é não-negativo no espaço \mathfrak{S} , então todos os autovalores λ de \tilde{S} são positivos [29]. Deseja-se, então, encontrar os autovetores v , e seus correspondentes autovalores, tal que $\lambda \geq 0$, que solucionam a equação:

$$\lambda v = \tilde{S}v. \quad (3.11)$$

Resumidamente pode-se entender o processo de cálculo do KPCA da seguinte forma:

- Projetar os dados do conjunto de entrada em um novo espaço amostral utilizando uma função kernel ϕ , este trabalho utilizou uma função gaussiana como função de ativação.

A partir daí seguir os passos normalmente utilizados para o cálculo do PCA, ou seja;

- Calcular o valor médio de cada amostra;
- Subtrair o valor médio do valor de cada variável;
- Calcular a matriz de covariância;
- Encontrar os autovalores e autovetores;
- Projetar os dados do conjunto original no novo espaço amostral, baseado nos m autovetores de maiores valores, que são as componentes principais, descorrelacionando-os.

3.3 Análise de Discriminantes Lineares

3.3.1 Breve Histórico



Figura 3.4: Ronald Aylmer Fisher.

Ronald Aylmer Fisher, representado na figura 3.4², nasceu em 17 de fevereiro de 1890, em Londres. Considerado o maior estatístico do século XX, Fisher foi aluno de Karl Pearson na *Caius e Goinville College*, em Cambridge, onde cursou matemática e astronomia, mas suas maiores contribuições seriam nos campos da estatística e da genética, sendo esta última uma de suas maiores paixões. Em 1919 Fisher ocuparia o cargo de estatístico-chefe na *Rothamsted Experimental Station* em Harpenden, no Reino Unido, desenvolvendo ali todos os princípios hoje conhecidos como Estatística Experimental. Em 1933 Fisher assumiria o posto de *Galton Professor of Eugenics* na *University College of London*, no lugar do seu antigo professor, Karl Pearson.

A forma que Fisher utilizava para solucionar problemas, normalmente envolvendo o raciocínio geométrico, e sua falta de afinidade para a oratória e a escrita tornavam complexa a tarefa de expressar suas ideias e transmiti-las a seus alunos. Essa dificuldade era perceptível nos textos que ditava para seus artigos e livros, mas em nada diminuía seu brilhantismo[43].

Entre os conceitos desenvolvidos por Fisher está o da Análise Multivariada de Discriminantes, ou Método Linear de Discriminantes de Fisher ou ainda e mais usualmente, Análise de Discriminantes Lineares. Surgida em 1936 esta técnica baseia-se no conceito do cálculo das componentes principais, desenvolvido por Pearson e Hotelling, mas supõe a possibilidade de lidar com diferentes grupos (método supervisionado) que formam um

²Fonte: <http://www.adelaide.edu.au/library/special/digital/fisher/>. Acesso em 09/05/2010.

conjunto de dados, possibilitando identificar diferenças entre esses grupos. No caso dos conjuntos de sinais mioelétricos, isso equivaleria a possibilidade de conhecer quais classes formam a matriz de dados X , explicitando as diferenças entre essas classes e entre as amostras que as compõem.

A principal diferença entre o PCA e a Análise de Discriminantes Lineares, ou simplesmente LDA (*Linear Discriminant Analysis*), apesar de ambos tratarem de extração de características lineares de conjuntos de dados n -dimensionais, é que o PCA enfatiza os dados mais representativos de um dado conjunto para tentar explicar seus padrões, enquanto o LDA procura explicar estes dados através da maximização da separabilidade inter-classes enquanto minimiza a variabilidade intra-classes.

3.3.2 Cálculo da Análise das Discriminantes Lineares

Para o cálculo do LDA, fica implícito que as matrizes de covariância de cada classe são iguais, pois a mesma matriz intra-classes é usada para todas as classes consideradas [22, 12].

Sejam S_b e S_w as matrizes inter e intra-classes, respectivamente, ou seja,

$$S_b = \sum_{i=1}^g N_i (\bar{x}_i - \bar{x})(\bar{x}_i - \bar{x})^T, \quad (3.12)$$

$$S_w = \sum_{i=1}^g \sum_{j=1}^{N_i} (x_{i,j} - \bar{x}_i)(\bar{x}_{i,j} - \bar{x})^T, \quad (3.13)$$

onde $x_{i,j}$ é a amostra j n -dimensional da classe i , N_i a quantidade de amostras da classe i , g o número total de classes ou grupos, \bar{x}_i a média da classe i e \bar{x} a média global de todas as amostras, descrito na equação (3.3) e reescrita abaixo:

$$\bar{x} = \frac{1}{N} \sum_{i=1}^g N_i \bar{x}_i = \frac{1}{N} \sum_{i=1}^g \sum_{j=1}^{N_i} x_{i,j}, \quad (3.14)$$

onde N é o total de amostras, tal que $N = N_1 + N_2 + \dots + N_g$. É importante notar que a matriz de espalhamento intra-classe S_w definida em (3.13) é essencialmente uma ponderação das matrizes de covariância de cada classe, tal que

$$S_w = \sum_{i=1}^g (N_i - 1) S_i = (N - g) S_p. \quad (3.15)$$

O LDA deve encontrar uma matriz de projeção Φ_{lda} que maximize a razão do determinante da matriz de espalhamento inter-classes para o determinante da matriz de espalhamento intra-classes, tal que

$$\Phi_{lda} = \underset{\Phi}{\operatorname{argmax}} \frac{|\Phi^T S_b \Phi|}{|\Phi^T S_w \Phi|}. \quad (3.16)$$

A equação (3.16) é maximizada quando a matriz de projeção Φ_{lda} é composta por autovetores de $S_w^{-1}S_b$ com pelo menos $(g - 1)$ autovalores não nulos correspondentes [33, 11].

De forma análoga ao PCA, a matriz de transformação Φ_{lda} é dada pelos autovetores de $S_w^{-1}S_b$ [47], tal que

$$\Phi_{lda}^T (S_w^{-1}S_b) \Phi_{lda} = \Lambda_{lda}. \quad (3.17)$$

3.3.3 Geometria das Discriminantes Lineares

Assim como as componentes principais, o LDA também é uma transformação linear de dados. Entretanto, se no PCA a rotação na coordenada dos eixos, definidos pelas variáveis originais do sistema, representa as direções de máxima variabilidade entre todas as amostras de todos os grupos, no LDA esta rotação representa as direções de máxima separação entre os grupos[10].

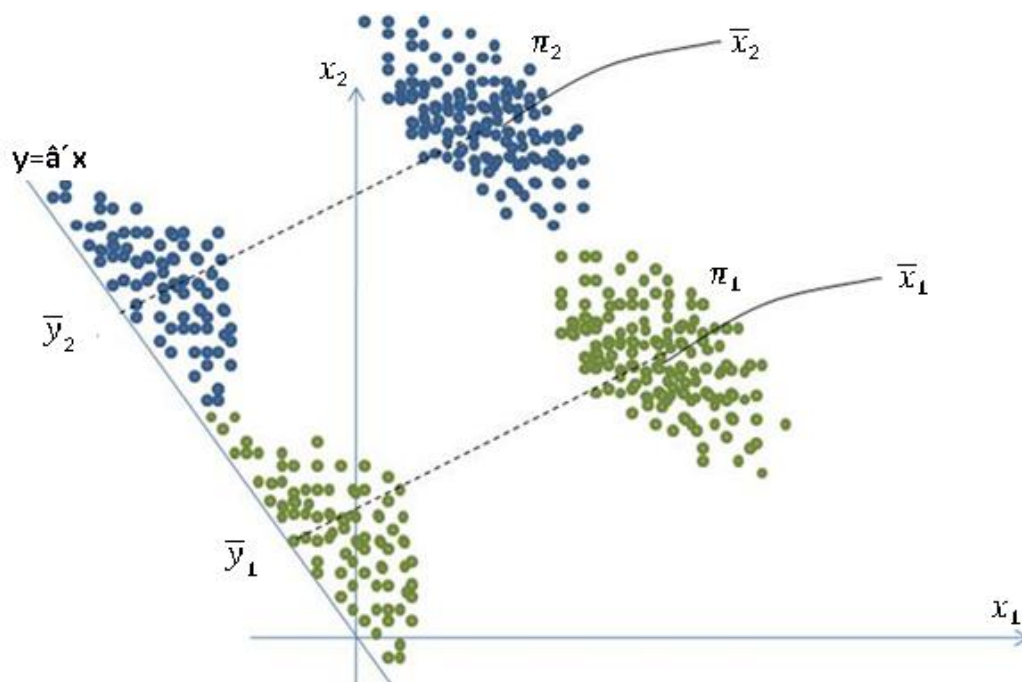


Figura 3.5: Ilustração do LDA para um conjunto de dados com dois grupos, nota-se o espalhamento dos dados com seus pontos projetados em uma linha na direção \hat{a} , que varia até que esses grupos estejam maximamente separados. Fonte: adaptado de [54].

A Figura 3.5 traz a representação do procedimento de Fisher para um caso com duas populações de amostras. Como pode-se perceber pelo espalhamento, todos os pontos estão projetados em uma linha na direção \hat{a} , esta direção é variada até que as amostras estejam maximamente separadas[54].

O principal propósito da LDA é, portanto, separar populações, podendo entretanto ser utilizada também para classificação. Esta técnica, entretanto, apresenta um sério problema de performance se utilizado com um número limitado de amostras N comparado à dimensão do espaço amostral n , uma vez que a matriz de espalhamento intra-classes S_w é uma função de $(N - g)$ vetores. Portanto, o posto da matriz S_w está limitado a $(N - g)$, tornando a sua inversão instável caso N seja menor ou comparável a n [12].

Maximum uncertainty Linear Discriminant Analysis

Em 2006, Thomaz et al. [12] propuseram uma nova abordagem para solucionar os problemas de singularidade e instabilidade envolvendo o LDA, quando utilizado com um conjunto limitado de amostras e com problemas envolvendo altas dimensionalidades. Esta abordagem baseia-se em um método direto de regularização da matriz de covariância

S_w . O método proposto, chamado MLDA (*Maximum uncertainty Linear Discriminant Analysis*), baseia-se na idéia da seleção da variância de máxima entropia, desenvolvida com o objetivo de melhorar a performance na classificação em problemas com limitação no tamanho do conjunto de amostras.

Considerando que o erro estimado para autovalores pequenos é muito maior do que o erro para autovalores maiores [33], Thomaz et al. [12] propuseram o seguinte algoritmo de seleção tal que apenas os pequenos autovalores de S_w sejam expandidos, preservando os maiores autovalores:

- Encontrar os autovetores Φ e autovalores Λ da matriz de covariância S_p , onde

$$S_p = S_w/[N - g]; \quad (3.18)$$

- Calcular a média dos autovalores de S_p , usando a equação

$$\bar{\lambda} = \frac{1}{n} \sum_{j=1}^n \lambda_j = \frac{tr(S_p)}{n}; \quad (3.19)$$

- Formar uma nova matriz de autovalores, baseada nos maiores valores de dispersão, ou seja,

$$\Lambda^* = diag[max(\lambda_1, \bar{\lambda}), \dots, max(\lambda_n, \bar{\lambda})]; \quad (3.20)$$

- Formar a matriz inter-classes modificada, isto é,

$$S_w^* = S_p^*(N - g) = (\Phi \Lambda^* \Phi^T)(N - g). \quad (3.21)$$

O MLDA substitui a matriz de covariância S_w por S_w^* na equação (3.17). Segundo Thomaz et al. [12], trata-se de um método direto que supera os problemas de singularidade e instabilidade do LDA, quando aplicado a problemas com limitação de amostras e alta dimensionalidade, além de ser um método computacionalmente viável.

3.4 Considerações Complementares

Após a descrição do cálculo e do comportamento geométrico dos métodos estatísticos e de análise multivariada, resumidos neste capítulo, a Análise das Componentes Principais foi avaliada como método de extração de informações dos conjuntos de dados, fornecidos pelos sinais mioelétricos e registrados conforme experimento a ser descrito no capítulo seguinte deste trabalho, assim como o LDA, regularizado pelo método do MLDA, foi avaliado por sua característica discriminante das classes que compõem os conjunto de dados, ajudando a evidenciar as diferenças entre os grupos e as características individuais dos sinais EMG. O KPCA foi utilizado como método para análise não linear da matriz de dados X , no intuito de comparar essa abordagem com o modelo linear, verificando se este modelo revela outras informações que ajudem na caracterização dos sinais mioelétricos

Capítulo 4

Experimentos e Resultados

4.1 Base de Dados

Este trabalho utilizou dados obtidos em um estudo anterior [49], sobre a relação entre o sinal mioelétrico(EMG) e o torque muscular isométrico de extensão da perna, aplicando diferentes níveis percentuais de contração isométrica máxima e em diferentes posições angulares. Esta seção descreve brevemente esta pesquisa e os materiais utilizados, explicando desta forma os meios pelos quais esta base de dados foi obtida, fornecendo o embasamento necessário para a compreensão dos dados analisados.

O estudo para a caracterização da relação entre os parâmetros eletromiográficos e o torque isométrico, através da análise dos sinais EMG, contou com a colaboração de 15 voluntários para a execução dos testes envolvidos na aquisição dos sinais, com idade variando entre 19,2 e 27,8 anos, altura de 172,3 a 178,4 cm, e peso de 68,2 a 72,6 kg, de ambos os sexos, saudáveis e sem registros antecedentes de lesões no aparelho locomotor. Os participantes efetuaram todos os exercícios utilizando sempre o membro inferior dominante, determinado pelo teste proposto por Peters [39], onde o sujeito deve chutar uma bola por três vezes consecutivas, adotando-se como membro dominante aquele que corresponder a pelo menos dois dos chutes efetuados [49]. O estudo foi aprovado pelo conselho de ética da Universidade São Judas Tadeu, e protocolado sob o n° 068/2004.

A aquisição dos sinais EMG procurou evidenciar características tais como a variabilidade e a intensidade do sinal mioelétrico, a sua correlação com os níveis de torque produzidos durante a realização dos movimentos com diferentes graus de extensão e níveis de torque aplicados.

4.1.1 Material

O experimento foi realizado com o auxílio de um sistema de aquisição de biopotenciais e a utilização de eletrodos de superfície, aderentes à pele, para a detecção e monitoramento do sinal mioelétrico [49]. Os instrumentos listados a seguir, foram utilizados para a captação dos sinais EMG e do torque e foram disponibilizados pelo laboratório de Biomecânica do Movimento Humano na Universidade São Judas Tadeu:

- Sistema de Aquisição de dados Eletromiográficos Myosystem (Noraxon USA);
- Software para armazenamento dos dados MyoResearch (Noraxon USA);
- Eletrodos de superfície descartáveis (Noraxon USA), sendo 2 eletrodos de captação e 1 de referência;
- Fita adesiva para fixação dos eletrodos;
- Dinamômetro isocinético Biodex System 3 (Biodex Medical Systems);
- Gerador Universal de corrente Nemesys (Quark);
- Esteira ergométrica Milk Plus (Queens).

O sistema Myosystem 1400 foi configurado para aquisição do sinal EMG conforme segue:

- Filtro passa-banda de 20 a 500Hz;
- Impedância de entrada $> 10M\Omega$;
- Taxa do modo comum de rejeição (CMRR) $> 85dB$;
- Taxa de ruído $< 1\mu V$ RMS;
- Amplificação total de 1000 vezes.

Os sinais EMG foram pré-amplificados diretamente pelos eletrodos de superfície, e em seguida também por um amplificador diferencial bipolar de oito canais. As figuras 4.1 e 4.2 mostram um exemplo de eletrodo de superfície, aderente à pele.



Figura 4.1: Exemplo de eletrodo de superfície aderente à pele, com um polo positivo e um negativo, para aquisição de sinais EMG.




Figura 4.2: Exemplo de eletrodos de superfície aderente à pele, para aquisição de sinais EMG. Cabo com eletrodos para múltiplos canais.

4.1.2 Procedimento

Durantes os procedimentos para a aquisição do sinal EMG os voluntários submeteram-se a uma tricotomia, ou seja, a remoção dos pelos, e a uma limpeza da pele com o objetivo de reduzir a resistência elétrica nos pontos em que foram aplicados os eletrodos bipolares de superfície. Portanto, todo o procedimento de aquisição foi realizado de forma não invasiva.

Para avaliação da atividade eletromiográfica, foram selecionados os seguintes músculos, nos quais foram posicionados os eletrodos: reto-femoral (RF), vasto lateral (VL), vasto

medial oblíquo (VMO) e vasto medial longitudinal (VML), todos pertencentes ao grupo agonista, ou seja, o grupo muscular cuja ação é a principal responsável pela execução do movimento. O grupo antagonista, por sua vez, é composto pelos músculos semitendíneo (ST), semimembráceo (SM), bíceps femoral cabeça longa (BFCL) e bíceps femoral cabeça curta (BFCC), este grupo muscular trabalha de modo a permitir o movimento exercido pelo grupo agonista, trabalhando de forma oposta, ou seja, alongando-se enquanto o grupo agonista se contrai. A localização dos pontos motores para a correta colocação dos eletrodos foi feita utilizando-se um gerador de pulso da marca Nemesys, com o eletrodo ativo (caneta), explorando a área de localização do ponto motor, e um eletrodo passivo (placa com esponja) posicionado na parte anterior da coxa contralateral [49]. O ponto motor corresponde ao ponto na pele sob o qual o músculo é mais excitável, contraindo-se com uma quantidade menor de corrente elétrica. Uma vez localizado, o ponto foi marcado e os eletrodos EMG colocados entre o ponto e a inserção distal do respectivo músculo, com uma distância de 2cm entre eles. Um eletrodo terra, do tipo monopolar, também foi posicionado sobre a patela [49]. As figuras 4.3¹ e 4.4 ilustram, respectivamente, os músculos quadríceps da coxa e o experimento com um voluntário no dinamômetro isocinético, já com os elementos de captação do sinal mioelétrico posicionados.

¹Fonte: www.mendmeshop.com/muscle/quadricep-strains.php. Acesso em 23/03/2010.

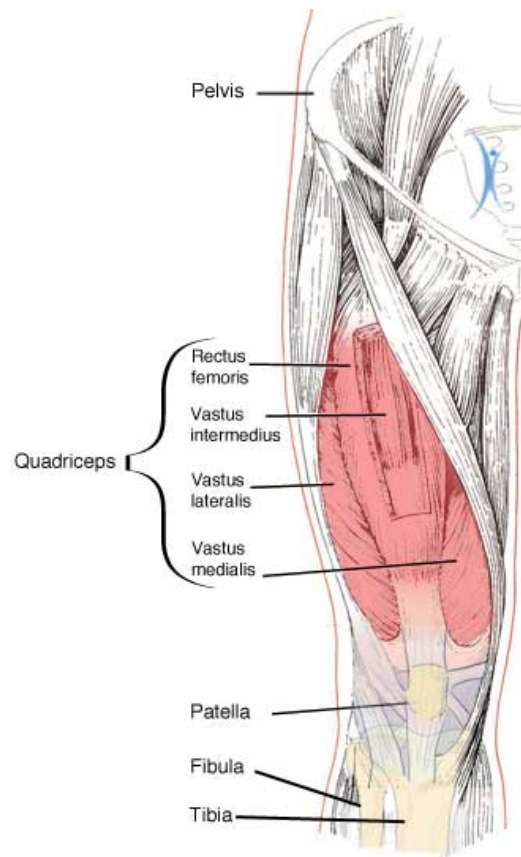


Figura 4.3: Ilustração do músculo quadríceps da coxa composto pelos músculos reto-femoral, vasto lateral, vasto medial oblíquo e vasto medial longitudinal.



Figura 4.4: Dinamômetro isocinético Biodesx System 3. Ilustração do experimento, com os eletrodos posicionados nos pontos pré-definidos nos músculos RF, VL, VML e VMO. Fonte [49].

A pesquisa, realizada no laboratório de Biomecânica do Movimento Humano da Universidade São Judas Tadeu, previa uma caminhada de 5 minutos em esteira, a uma velocidade de 3km/h, como aquecimento inicial. Os voluntários passaram então para o dinamômetro isocinético, onde foram executados os exercícios de extensão da perna. Um breve exercício de 2 minutos para extensão da perna foi feito no intuito de possibilitar a adaptação do indivíduo à máquina.

O exercício a que os voluntários se submetiam consistia na contração isométrica, com diferentes níveis de força, para o movimento de contração da perna nos ângulos 0° , 20° , 40° , 60° , 80° e 100° (posição da perna totalmente estendida). Para cada nível de força solicitado (0%, 20%, 40%, 60%, 80% e 100% da contração voluntária isométrica máxima, ou CVIM), foi realizado cinco contrações de 5 segundos com um intervalo de 15 segundos entre as mesmas, em cada uma das 6 posições angulares. Entre as mudanças na posição angular, teve-se o cuidado de estabelecer um intervalo de 3 minutos de repouso, para evitar a fadiga muscular [49].

A figura 4.5 ilustra o exercício durante o qual o voluntário executava as sequências pré-definidas para o exercício. Posicionando o braço de alavanca do dinamômetro na posição 0° , (com a perna paralela à coxa) por exemplo, o voluntário executava 1 contração isométrica de 5 segundos, seguida de uma pausa de 15 segundos. Após cinco repetições havia uma pausa de 3 minutos para evitar a fadiga muscular. O braço de alavanca do dinamômetro era então posicionado a 20° e a mesma sequência era repetida até que se atingisse 100° . O monitor do dinamômetro isocinético fornecia os valores gerados durante a realização do exercício, fornecendo a informação necessária para a execução correta do exercício, permitindo que os níveis de torque gerados estivessem dentro dos limites determinados para cada indivíduo.



Figura 4.5: Ilustração do experimento. Durante o exercício realizado, o monitor do dinamômetro isocinético fornecia o feedback do torque que estava sendo gerado pelo voluntário, possibilitando o controle do experimento. Fonte [49].

A tabela 4.1 mostra um exemplo de tabulação dos valores registrados em cada nível de torque (% CVIM), para cada posição angular ($^{\circ}$). Após a realização da primeira aquisição, considerando esta 100% da CVIM, foi calculado o intervalo de torque em que o voluntário deveria executar as demais contrações, com uma tolerância de $\pm 5\%$ do valor total.

Posição Angular (°)						
Torque (% CVIM)	0°	20°	40°	60°	80°	100°
100%	33 Nm	53 Nm	92 Nm	112 Nm	132Nm	102Nm
80%	28 Nm	45 Nm	78 Nm	95 Nm	112Nm	87Nm
	25 Nm	40 Nm	69 Nm	84 Nm	99Nm	77Nm
60%	21 Nm	34 Nm	60 Nm	73 Nm	86Nm	66Nm
	18 Nm	29 Nm	51 Nm	62 Nm	73Nm	56Nm
40%	15 Nm	24 Nm	41 Nm	50 Nm	59Nm	46Nm
	12 Nm	19 Nm	32 Nm	39 Nm	46Nm	36Nm
20%	8 Nm	13 Nm	23 Nm	28 Nm	33Nm	26Nm
	5 Nm	8 Nm	14 Nm	17 Nm	20Nm	15Nm

Tabela 4.1: Tabela Posição Angular x Torque. Exemplo do cálculo efetuado para determinar os valores percentuais em cada nível de torque, considerando a primeira aquisição como 100% do valor da CVIM, calculou-se a faixa de torque e o intervalo de tolerância de $\pm 5\%$ do valor total da CVIM[49].

A figura 4.6 mostra um exemplo da tela do monitor do dinamômetro isocinético, onde era possível acompanhar o valor do torque que estava sendo gerado pela contração muscular do voluntário, durante a execução do exercício, através das faixas de referência.

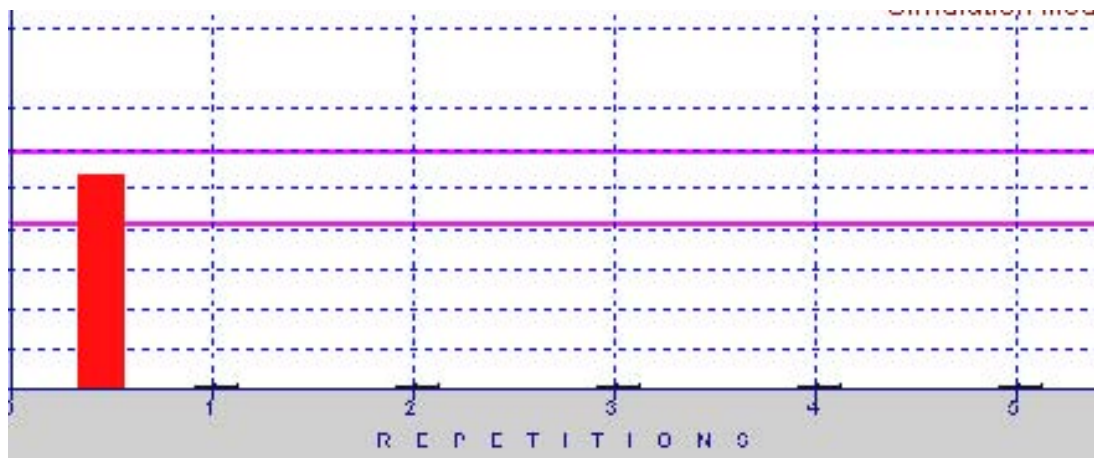


Figura 4.6: Tela do monitor do dinamômetro isocinético. Referência para graduação do torque exercido durante a execução do exercício. Fonte: [49].

A figura 4.7 ilustra como os dados registrados durante a aquisição dos sinais mioelétricos foram armazenados. Existe um arquivo para cada voluntário, contendo os valores EMG correspondentes aos músculos dos grupos agonista: (RF), (VL), (VMO) e (VML)), e antagonista: (ST),(SM),(BFCL) e (BFCC). Cada arquivo registrou aproximadamente

90 segundos de dados registrados, ou 90.000 ms.

[HEADER]													
Name	adr00a00												
Frequency	1000												
Date	4/2/2006												
[DATA]													
Time	RECTUS FEM.,uV	VLO,uV	VML,uV	VMO,uV	BICEPS FEM.	BICEPS FEM. CC,uV	SEMIMEM BR.,uV	SEMITEN D.,uV	torque N*m	velocidade graus/s	posição graus	sincronização on/off	Activities
0.000	251.473	202.628	-13.427	0.830026	105.085	0.219637	0.14706	0.68371	0.34638	0.287263	0.527333	0.0392153	0
0.001	0.0731461	-0.414987	109.855	0.830026	105.085	-222.174	0.14706	-175.775	-0.331393	-0.212325	-0.219488	-0.131687	0
0.002	0.0731461	-0.414987	109.855	-16.113	-139.159	0.219637	0.14706	0.68371	-0.331393	0.787476	0.0793029	-0.0730944	0
0.003	0.0731461	202.628	109.855	-16.113	-139.159	0.219637	0.14706	-175.775	-0.331393	-0.462743	0.0793029	-0.0340386	0
0.004	0.0731461	-0.414987	-13.427	0.830026	-139.159	0.219637	-229.717	-175.775	0.34638	0.537682	0.378094	0.053859	0
0.005	0.0731461	-0.414987	-13.427	0.830026	105.085	0.219637	-229.717	0.68371	-101.083	0.0374691	-0.219488	0.029447	0
0.006	0.0731461	202.628	-13.427	-16.113	105.085	0.219637	0.14706	-41.992	170.193	0.0374691	0.527333	-0.0877381	0
0.007	0.0731461	-0.414987	109.855	0.830026	105.085	0.219637	0.14706	-175.775	-16.886	0.0374691	-0.219488	-0.146331	0
0.008	-236.822	-0.414987	-13.427	-16.113	105.085	0.219637	0.14706	312.485	102.415	0.287263	0.527333	-0.00962655	0
0.009	0.0731461	-0.414987	109.855	0.830026	-139.159	0.219637	0.14706	312.485	-16.886	0.0374691	-0.518591	0.0782711	0
0.010	0.0731461	-0.414987	-13.427	0.830026	-139.159	0.219637	0.14706	0.68371	-0.331393	0.287263	0.378094	-0.141455	0
0.011	0.0731461	-0.414987	-13.427	-16.113	-139.159	0.219637	0.14706	312.485	-0.331393	-0.212325	-0.0702486	0.0587344	0
.
.
.
89.996	0.0731461	202.628	109.855	-16.113	-139.159	0.219637	0.14706	0.68371	-105.013	40.373	261.918	0.0929148	0
89.997	0.0731461	-0.414987	-378.414	-16.113	-139.159	0.219637	0.14706	0.68371	-118.569	328.729	187.205	0.107576	0
89.998	0.0731461	202.628	-13.427	0.830026	105.085	266.123	0.14706	-41.992	-111.791	40.373	261.918	0.0782711	0
89.999	-236.822	-0.414987	3.54	-16.113	349.042	0.219637	258.622	0.68371	-118.569	37.875	20.216	0.136864	0
90.000	0.0731461	-0.414987	109.855	-16.113	349.042	0.219637	0.14706	312.485	-982.355	40.373	276.873	0.127095	0
90.001	0.0731461	202.628	-13.427	0.830026	349.042	-466.312	0.14706	0.68371	-132.124	40.373	187.205	0.0929148	0
90.002	0.0731461	-0.414987	-13.427	-16.113	105.085	-222.174	0.14706	0.68371	-982.355	353.771	276.873	0.12222	0
90.003	251.473	-0.414987	109.855	0.830026	105.085	266.123	258.622	0.68371	-132.124	428.771	217.084	0.0733958	0
90.004	-236.822	-0.414987	-13.427	0.830026	105.085	0.219637	258.622	312.485	-982.355	353.771	246.994	0.161276	0
90.005	0.0731461	-0.414987	-13.427	-16.113	105.085	0.219637	0.14706	0.68371	-118.569	37.875	187.205	0.0831464	0
90.006	-236.822	-0.414987	109.855	0.830026	-139.159	0.219637	0.14706	0.68371	-105.013	353.771	261.918	-0.0047335	0
90.007	0.0731461	-0.414987	109.855	-16.113	-383.402	0.219637	0.14706	312.485	-125.346	37.875	20.216	0.127095	0
90.008	0.0731461	-0.414987	109.855	0.830026	-383.402	0.219637	0.14706	312.485	-105.013	328.729	261.918	0.0733958	0

Figura 4.7: Exemplo ilustrando a organização dos dados registrados em arquivos individuais para cada voluntário em função do exercício executado.

Cada arquivo registra os dados da aquisição de um voluntário, referente a um determinado ângulo e torque. Por exemplo, para o arquivo nomeado adr20a40, os 3 primeiros dígitos identificam o sujeito (adr), os dígitos 4 e 5 identificam o ângulo no qual o experimento foi executado (20°) e os dígitos 6 e 7 identificam o nível percentual do torque exercido naquele determinado ângulo (40%), totalizando 540 tabelas com aproximadamente 90 segundos de dados registrados, correspondentes aos dados registrados para 15 voluntários x 6 ângulos x 6 níveis percentuais do torque máximo da CVIM.

4.2 Experimentos

Os dados gerados durante a pesquisa descrita sucintamente na seção anterior foram separados de modo a formar os conjuntos e classes necessários para possibilitar o estudo e a caracterização do torque do músculo quadríceps da coxa, através do sinal EMG bruto, ou seja, utilizado exatamente como foi registrado, a não ser o condicionamento inicial do sinal feito pelo sistema de aquisição.

Esta seção de experimentos explica como esses grupos foram formados e como são combinados para possibilitar a caracterização do sinal mioelétrico, em função do torque, a partir da base de dados disponível.

4.2.1 Composição da informação relevante para a caracterização do sinal EMG

Para a formação dos grupos, utilizou-se os dados de 9 dos 15 voluntários disponíveis, em função da integridade e disposição das informações registradas, dada a especificidade das características envolvidas nos cálculos destes conjuntos. Para este estudo, considerou-se apenas o grupo de músculos agonistas, ou seja, RF, VL, VMO e VML, que correspondem aos quatro primeiros músculos mostrados na tabela 4.7. Esta escolha deve-se ao fato de o conjunto antagonista parecer não interferir na correlação existente entre o sinal EMG e o torque exercido pelos músculos agonistas, segundo [49].

Nesta etapa, foram definidas as classes que serão o objeto de estudo para este trabalho. Os dados disponíveis foram distribuídos em 216 tabelas de 6 (níveis percentuais do torque máximo da CVIM) x 90.000 (ms) elementos, correspondendo aos testes executados pelos voluntários. Estes dados foram dispostos em função do torque registrado, uma vez que deseja-se investigar as características do sinal EMG em função do torque isométrico. Portanto, as tabelas correspondem ao registro dos dados para 9 sujeitos x 6 ângulos x 4 músculos = 216 tabelas, compostas conforme segue:

– Arquivo aaatnm, onde aaa corresponde ao nome do indivíduo que executou o exercício e tt indica o nível percentual do torque máximo da CVIM para o exercício executado. Por exemplo, o arquivo adr00Nm corresponde ao grupo de dados referentes aos registros dos exercícios executados pelo voluntário adr, para o torque 00nm, incluindo

os ângulos 0°, 20°, 40°, 60°, 80° e 100°, para os músculos RF, VL, VMO e VML.

Durante os estudos realizados, essas tabelas foram rearranjadas e renomeadas, formando novos grupos, e tratadas como matrizes de dados que podem ser estudadas individualmente, fornecendo informações sobre o comportamento do sinal mioelétrico para um determinado teste com um voluntário, com um determinado músculo, ou agrupadas possibilitando a extração de uma informação comum para diferentes testes, utilizando os dados de mais de um voluntário. Isto permitiu a realização de diversos experimentos, com diferentes níveis de complexidade e resultados, quanto ao grau de separabilidade dos grupos e à caracterização do torque isométrico do músculo quadríceps da coxa.

A seguir tem-se alguns exemplos para a formação do grupo de sinais EMG para o estudo dos músculos agonistas:

– Arquivos nomeados “mmtt”, onde mm corresponde ao músculo e tt ao nível percentual do torque aplicado. No exemplo RF20, o arquivo corresponde ao grupo composto pelos sinais EMG registrados durante os exercícios executados pelos 9 voluntários, considerando todos os ângulos, a partir do músculo reto-femoral, ou RF, a 20% da CVIM.

Exemplo da composição de sinais EMG para formação das classes cujo objetivo é o estudo do torque isocinético:

- T0 - Grupo composto pelos sub-grupos RF00, VL00, VMO00 e VML00, para o nível percentual de torque 00% ;
- T20 - Grupo composto pelos sub-grupos RF20, VL20, VMO20 e VML20, para o nível percentual de torque 20%;
- T40 - Grupo composto pelos sub-grupos RF40, VL40, VMO40 e VML40, para o nível percentual de torque 40%;
- T60 - Grupo composto pelos sub-grupos RF60, VL60, VMO60 e VML60, para o nível percentual de torque 60%;
- T80 - Grupo composto pelos sub-grupos RF80, VL80, VMO80 e VML80, para o nível percentual de torque 80%;
- T100 - Grupo composto pelos sub-grupos RF100, VL100, VMO100 e VML100, para o nível percentual de torque 100%.

Esses grupos foram combinados em uma matriz de dados X, maior e mais complexa, que abrange todos os níveis percentuais de torque e todos os ângulos, para os 4 músculos agonistas e para os 9 voluntários, dessa forma $X = [X1_{ijkl}, X2_{ijkl}...XN_{ijkl}]$, com i = percentual do torque exercido, j = músculo, k = sujeito e l = ângulo. Essa configuração da matriz X permitiu testar a capacidade de generalização de classificadores linear e não linear, para o reconhecimento do sinal mioelétrico independentemente do voluntário que realizou os testes, do músculo que forneceu o sinal EMG ou do ângulo na qual a perna estava posicionada no momento da aquisição. A figura 4.8 mostra um exemplo da organização dos dados na matriz X.

	T0																		= Percentual do torque exercido X 6			
	RF												VLO							= Musculo X 4		
	Adr						Ana						Thi								= Sujeito X 9	
	0	20	40	60	80	100	0	20	40	60	80	100	0	20	40	60	80	100				= Ângulo da perna X 6
1																						
2																						
3																						
4																						
5																						
6																						
7																						
8																						
9																						
10																						
.																						
.																						
.																						
90000																						

Figura 4.8: Ilustração da organização dos dados correspondentes aos sinais mioelétricos na matriz de dados X formada pelos dados correspondentes a: 6 níveis percentuais do torque exercido, 4 músculos agonistas, 9 sujeitos e 6 ângulos de posicionamento da perna.

Inicialmente as classes estudadas foram plotadas em gráficos de dispersão para avaliar a possibilidade de uma análise direta dos sinais mioelétricos. As classes com menor grau de complexidade, ou seja, aquelas com menor quantidade de amostras, permitiram uma avaliação imediata do sinal EMG registrado. Na figura 4.9 podemos observar a distribuição dos dados referentes ao sinal EMG, registrados a partir da aquisição feita para um único voluntário, referentes aos músculos RF, VL, VML e VMO, nos ângulos 0°, 20°, 40°, 60°, 80° e 100°, durante contração isométrica a 40% da CVIM. Mesmo utilizando o sinal bruto, é possível perceber o alinhamento na distribuição entre as amostras, tornando evidente que o experimento foi controlado e bem realizado.

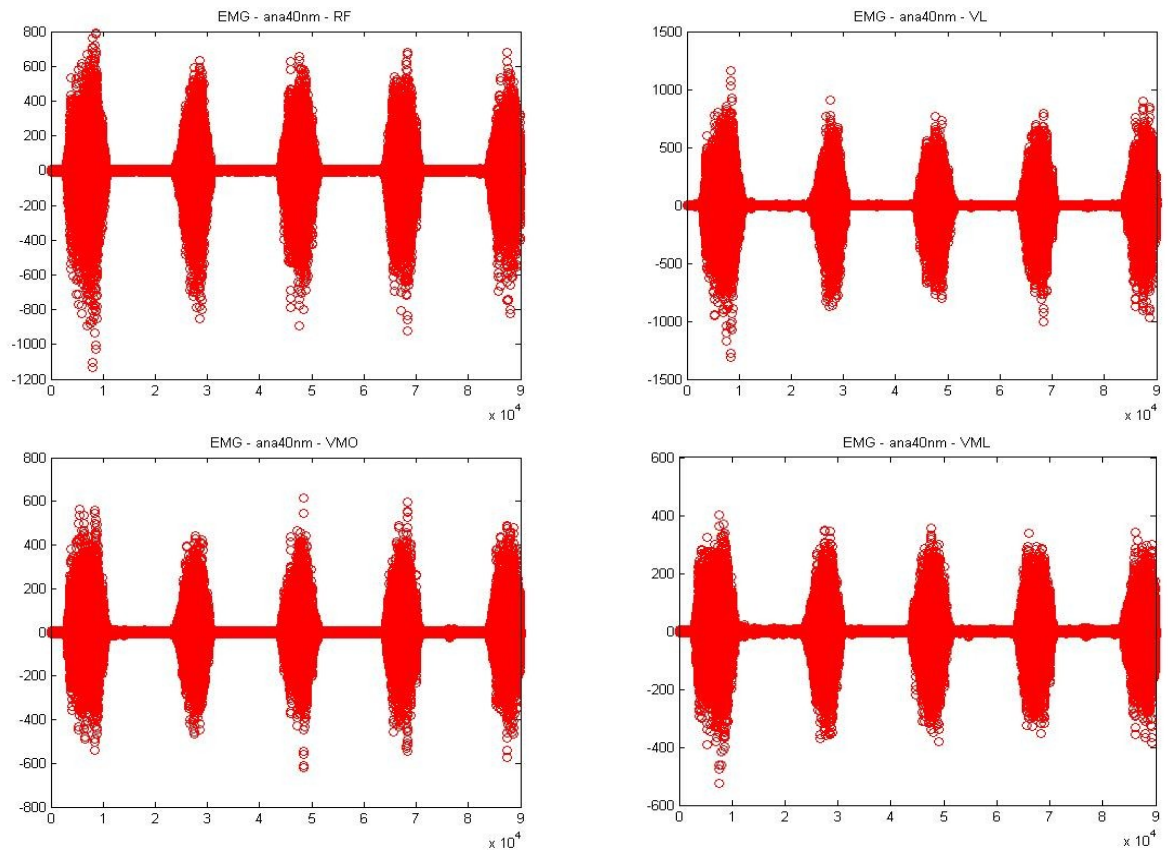


Figura 4.9: Ilustração da distribuição dos dados mioelétricos do músculo RF, VL, VML e VMO, para um voluntário, considerando os ângulos 00° , 20° , 40° , 60° , 80° e 100° , a 40% da CVIM durante contração isométrica, onde percebe-se uma boa simetria no espalhamento dos dados ainda que considerando amostras de diferentes músculos.

Em seguida, desta vez utilizando classes mais complexas e com maior número de informações, foram plotados gráficos de dispersão para os sinais EMG com o intuito de verificar se ainda seria possível distinguir as características básicas do sinal, ou seja, se esse novo conjunto manteria uma estrutura similar a dos conjuntos de dados mais simples que o formaram, ainda que agora os dados correspondam aos sinais EMG de todos os 9 voluntários, unidos em um mesmo grupo cujo objetivo é evidenciar o torque percentual exercido. As figuras 4.10, 4.11, 4.12, 4.13, 4.14 e 4.15, mostram a distribuição do sinal EMG para as classes T00, T20, T40, T60, T80 e T100. Pode-se verificar pelas imagens, que os sinais continuam bem sincronizados, o que auxiliará durante a análise multivariada dos dados pois, uma vez que o sinal mioelétrico será representado como um vetor, em uma matriz com N linhas x p colunas, é desejável que haja correspondência entre estes.

É possível verificar também, através da figura 4.10, que o grupo referente às aquisições realizadas a 0% da CVIM, apresenta um padrão diferente na distribuição dos dados correspondentes aos sinais EMG. A partir da análise dessa imagem alguns testes foram realizados, utilizando o PCA como ferramenta para uma transformação linear desses dados, e foi possível constatar que esta classe, quando presente na formação de outros conjuntos, não contribuía para a extração das características do sinal mioelétrico nem fornecia dados discriminantes. Dessa forma, a classe correspondente ao torque percentual 00nm foi removida da composição dos demais conjuntos.

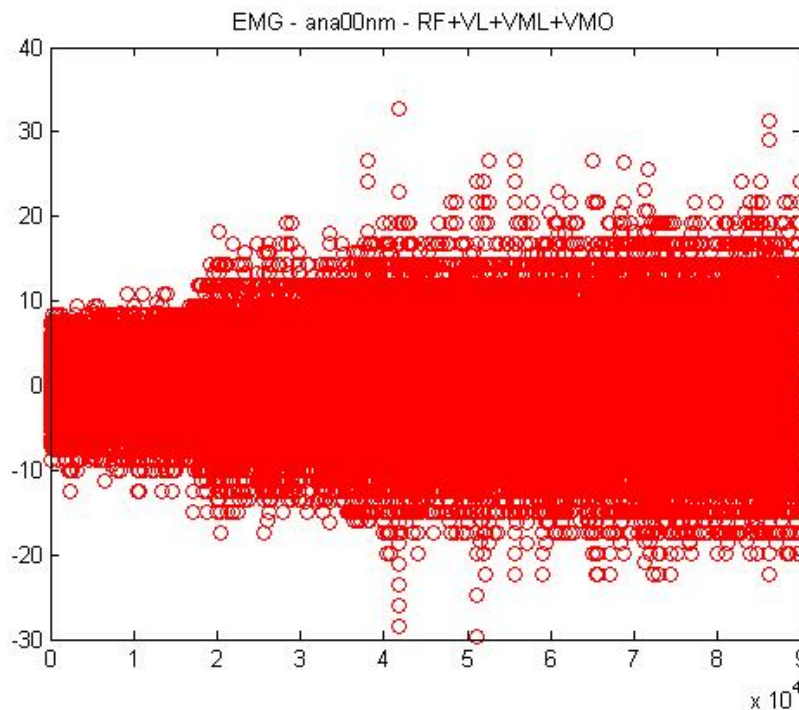


Figura 4.10: Ilustração da distribuição dos dados mioelétricos para o grupo T00, composto pelos músculos RF, VL, VML e VMO, para um voluntário, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 00% da CVIM. Pode-se observar aqui, um padrão diferente na distribuição dos dados, quando comparado às demais classes estudadas, o que justificou a remoção desta classe na formação da matriz de dados X .




Figura 4.11: Ilustração da distribuição dos dados mioelétricos para o grupo T20, composto pelos músculos RF, VL, VML e VMO, para um voluntário, considerando os ângulos 00° , 20° , 40° , 60° , 80° e 100° , a 20% da CVIM.




Figura 4.12: Ilustração da distribuição dos dados mioelétricos para o grupo T40, composto pelos músculos RF, VL, VML e VMO, para um voluntário, considerando os ângulos 00° , 20° , 40° , 60° , 80° e 100° , a 40% da CVIM.




Figura 4.13: Ilustração da distribuição dos dados mioelétricos para o grupo T60, composto pelos músculos RF, VL, VML e VMO, para um voluntário, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 60% da CVIM.




Figura 4.14: Ilustração da distribuição dos dados mioelétricos para o grupo T80, composto pelos músculos RF, VL, VML e VMO, para um voluntário, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 80% da CVIM.

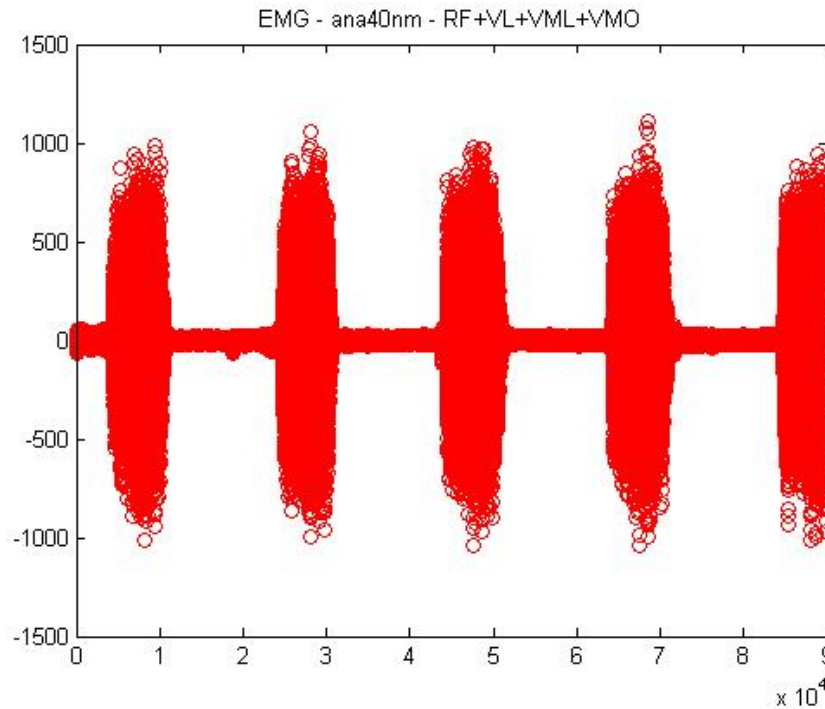


Figura 4.15: Ilustração da distribuição dos dados mioelétricos para o grupo T100, composto pelos músculos RF, VL, VML e VMO, para um voluntário, considerando os ângulos 00° , 20° , 40° , 60° , 80° e 100° , a 100% da CVIM.

Pela observação dos conjuntos de dados estudados e das imagens dos gráficos de dispersão do sinal mioelétrico, verificou-se que um pós-processamento do sinal seria desejável uma vez que, como pode-se observar na figura 4.15, por exemplo, as pausas realizadas entre os exercícios de contração do músculo quadríceps, correspondem a um volume considerável da informação presente em todos os registros, entretanto esses intervalos não trazem nenhum dado discriminante para o estudo e caracterização do sinal EMG, contribuindo apenas para o aumento na dimensão dos dados estudados. Sendo assim, foi desenvolvido um filtro, baseado na imagem média dos sinais mioelétricos para os conjuntos ou classes de dados estudados, possibilitando uma redução inicial na dimensão dos dados, reduzindo o esforço computacional exigido durante o seu processamento.

A ideia para remoção dos intervalos correspondentes ao repouso dos músculos surgiu através da analogia entre o sinal EMG e uma imagem qualquer, por exemplo uma figura onde é possível determinar quais áreas são de interesse e quais podem ser desprezadas. A partir dessa premissa, extraiu-se o valor médio para a matriz de dados X , com dimensão em \mathfrak{R}^{90000} , representando todas as classes envolvidas nos testes para a caracterização do sinal mioelétrico. Uma imagem $\bar{X} = \frac{1}{N} \sum_{j=1}^N X_j$ desse conjunto de dados foi gerada em

um quadro de 300 x 300 pixels, evidenciando apenas os pontos onde havia informação correspondente ao exercício realizado. A figura 4.16 mostra essa imagem, onde é possível perceber claramente os momentos onde o exercício de contração do músculo era realizado, destacando-se pelo contraste dos pixels brancos (contração) contra o fundo preto (repouso).

Essa imagem foi utilizada como base para construção do filtro para os intervalos correspondentes ao repouso durante os exercícios. O procedimento aplicado consistiu da verificação do início e fim das faixas que contêm informação útil (faixas brancas) na imagem, e então a utilização dessa informação para selecionar os dados nas matrizes estudadas. Os intervalos selecionados foram: 5701 até 9301; 26401 até 30001; 45601 até 49601; 66001 até 69001 e 85801 até 89401, correspondentes aos pontos de início e fim das colunas com informação relevante. A nova matriz de dados teve uma redução de 90.000 dimensões iniciais para 17.405.




Figura 4.16: Imagem média do sinal mioelétrico, construída a partir da matriz de dados X, e utilizada para construção de um filtro para remoção dos intervalos correspondentes às pausas para repouso, efetuadas durante os exercícios, com I1 (5701 até 9301); I2 (26401 até 30001); I3 (45601 até 49601); I4 (66001 até 69001) e I5 (85801 até 89401).

4.3 Resultados

4.3.1 Análise visual empregando um modelo linear para tratamento dos dados

Uma vez determinadas as classes que deseja-se estudar, o PCA foi utilizado como ferramenta para a análise destes dados, reduzindo sua dimensionalidade e explicando a covariância entre os grupos de variáveis através de combinações lineares [33]. Após o PCA, cada registro do sinal mioelétrico, antes representado em um espaço de 17405 dimensões, isto é, \mathbb{R}^{17405} , passou a ser representado em um espaço \mathbb{R}^2 ou \mathbb{R}^3 , para análise visual da dispersão desses dados.

Podemos observar essa transformação no exemplo que segue. A Figura 4.17 traz o gráfico de dispersão para a classe T40 onde, apesar da grande quantidade de informações contidas neste conjunto de dados, não é possível extrair informações relevantes ou discriminantes quanto as classes que o compõe. A figura 4.18, mostra o gráfico gerado a partir da transformação linear desses dados, através do PCA.

Com o intuito de verificar quão discriminantes poderiam ser os sinais provenientes do músculo quadríceps da coxa, considerando os exercícios executados por todos os 9 voluntários, independentemente do músculo e do ângulo no qual o exercício foi realizado, a matriz de dados X foi transformada linearmente. A Figura 4.19 mostra a distribuição de dados para este conjunto, após o PCA.

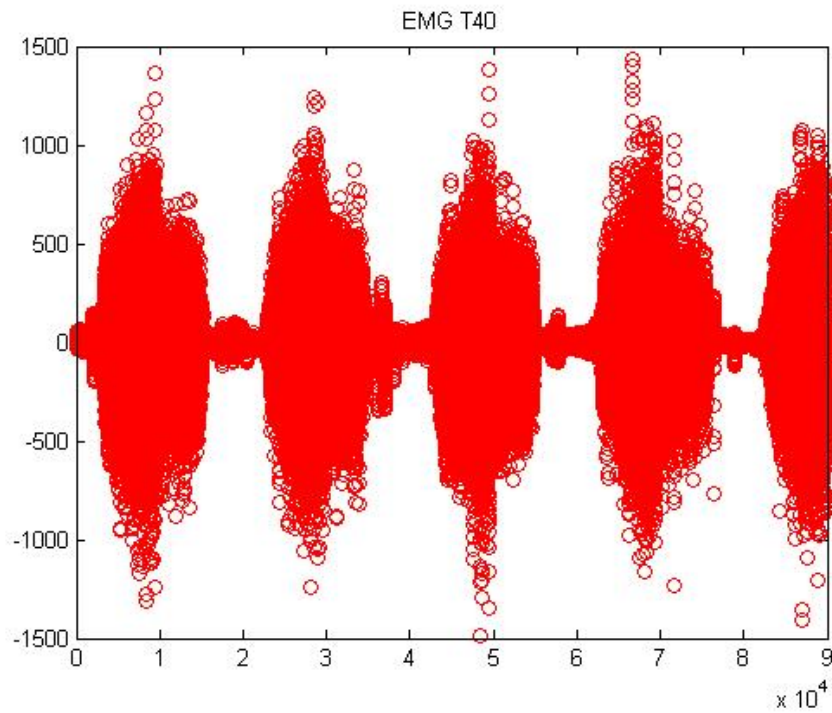


Figura 4.17: Ilustração da distribuição dos dados mioelétricos para o grupo T40, composto pelos músculos RF, VL, e VMO VML , considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 40% da CVIM.




Figura 4.18: Ilustração da distribuição dos dados mioelétricos do músculo quadríceps da coxa para o conjunto T40 no espaço tridimensional, utilizando as 3 componentes principais de maior valor X_1 , X_2 e X_3 após a transformação linear com o PCA. Ainda Não é possível perceber nenhum padrão que auxilie na discriminação das informações correspondentes aos músculos RF, VL, VML e VMO.




Figura 4.19: Distribuição dos dados mioelétricos do músculo quadríceps da coxa, para o conjunto X no espaço tridimensional, ilustração utilizando as 3 componentes principais de maior valor X_1 , X_2 e X_3 . Após a transformação linear com o PCA é possível perceber algumas informações dos conjuntos de dados correspondentes aos músculos RF, VL, VML e VMO, mas visualmente ainda não é possível extrair qualquer informação expressiva.

Pode-se perceber, a partir dessa distribuição dos dados nas figuras anteriores, que ainda não é possível identificar nenhuma informação relevante, que auxilie na caracterização do sinal mioelétrico. O MLDA foi utilizado então para melhorar os resultados obtidos, evidenciando as diferenças entre os grupos observados [12].

As Figuras 4.20, 4.21, 4.22 e 4.23 mostram, respectivamente, a representação do conjunto T40 e da matriz X, após a transformação linear com o PCA e o MLDA. Enquanto a figura 4.20 não diz muito sobre as características deste conjunto de dados após o processamento com o PCA, na figura 4.21, após o processamento com o MLDA, é possível perceber que as regiões de interesse estão bem definidas, observando-se nitidamente a separabilidade entre as classes que representam os músculos RF, VL, VMO e VML. Agora é possível identificar as regiões que representam cada um dos músculos que formam os quadríceps, durante o trabalho de contração isométrica, com o músculo reto-femoral representado à direita do gráfico, em uma região definida e com um espalhamento relativamente uniforme, o músculo vasto lateral, à esquerda do gráfico apresenta também as mesmas características, com alguma sobreposição com os dados correspondentes aos músculos vasto medial oblíquo e vasto medial lateral, representados respectivamente nas regiões superior e inferior do gráfico, também em função do ângulo em que o gráfico 3-D está rotacionado.




Figura 4.20: Ilustração da distribuição dos dados mioelétricos do músculo quadríceps da coxa para o conjunto T40 no espaço tridimensional, utilizando as 3 componentes principais de maior valor X1, X2 e X3 após a transformação linear com o PCA. Ainda Não é possível perceber nenhum padrão que auxilie na discriminação das informações correspondentes aos músculos RF, VL, VML e VMO.




Figura 4.21: Ilustração da distribuição dos dados mioelétricos do músculo quádriceps da coxa para o conjunto T40 no espaço tridimensional, utilizando as 3 componentes principais de maior valor X_1 , X_2 e X_3 após a transformação linear com o PCA e o MLDA. Aqui já é possível uma análise visual dos dados, com o espalhamento correspondentes aos músculos RF, VL, VML e VMO em áreas bem definidas, o que sugere uma boa separabilidade dos dados.

A Figura 4.22 também não permite uma análise direta dos dados quando processados apenas com o PCA, mas após o processamento da matriz de dados X, com o PCA e MLDA, pode-se perceber na Figura 4.23, que mesmo considerando todos os conjuntos de dados, ou seja, todos os ângulos e torques de todos os voluntários, há uma excelente separabilidade entre as classes T20, T40, T60, T80 e T100, visualmente ainda melhor do que o conjunto de dados formado apenas pelos grupo T40, permitindo ver claramente as regiões onde ocorre o espalhamento dos dados, bem definidas para cada uma das classes, com os torques percentuais correspondentes a 80% e 60% distribuídos respectivamente à esquerda e à direita do gráfico, 40% e 100% com regiões bem definidas respectivamente acima e abaixo da região central, ocupada pelo torque percentual correspondente a 20%.




Figura 4.22: Distribuição dos dados mioelétricos do músculo quadríceps da coxa, para o conjunto X, no espaço tridimensional, utilizando as 3 componentes principais de maior valor X1, X2 e X3 após a transformação linear com o PCA. De modo análogo ao conjunto T40, após a transformação linear do conjunto X com o PCA ainda não é possível distinguir características individuais correspondentes a 20%, 40%, 60%, 80% e 100% do torque percentual aplicado.

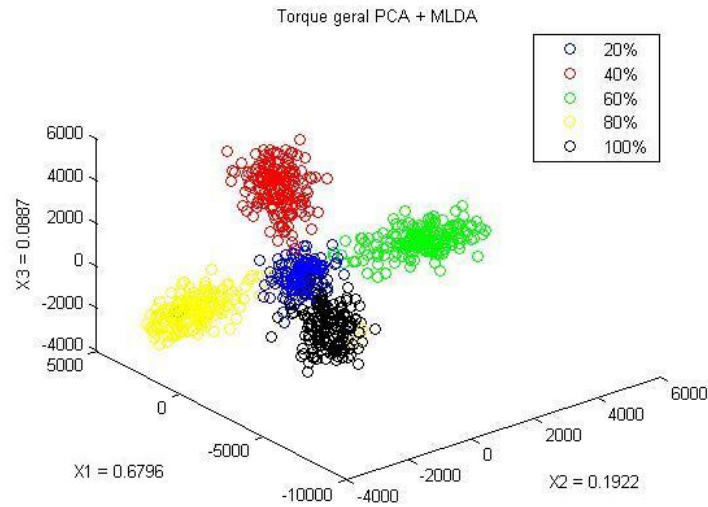


Figura 4.23: Distribuição dos dados mioelétricos do músculo quadríceps da coxa para o conjunto X no espaço tridimensional, utilizando as 3 componentes principais de maior valor X1, X2 e X3 após a transformação linear com o PCA e o MLDA. A Figura permite uma análise visual dos dados, com o espalhamento correspondentes aos níveis de torques percentuais aplicados caracterizados em áreas bem definidas, sugerindo uma boa separabilidade dos dados.

A partir dessa informação foi possível determinar a viabilidade da caracterização do torque isométrico do músculo quadríceps da coxa, independentemente do sujeito e do ângulo em que o exercício foi executado, utilizando os sinais registrados com os músculos agonistas.

Após essa primeira análise visual do conjunto de dados correspondente à matriz X, o comportamento isolado dos músculos agonistas foi estudado, com o intuito de determinar se a contribuição muscular para os diferentes níveis percentuais de contração era equivalente para todos os músculos, ou se um determinado músculo fornecia uma contribuição mais significativa para a caracterização do torque. As figuras 4.24, 4.25, 4.26, 4.27 e 4.28 mostram a distribuição dos dados referentes aos sinais EMG, para os músculos RF, VLO, VML e VMO a 20%, 40%, 60%, 80% e 100% da CVIM máxima.




Figura 4.24: Ilustração da distribuição dos dados mioelétricos para o grupo T20, composto pelos músculos músculos RF, VL, VML e VMO, com 9 voluntários, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 20% da CVIM, com as componentes principais X1, X2, e X3 explicando respectivamente 6,42%, 3,81% e 3,51% da variância total dos dados.




Figura 4.25: Ilustração da distribuição dos dados mioelétricos para o grupo T40, composto pelos músculos músculos RF, VL, VML e VMO, com 9 voluntários, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 40% da CVIM, com as componentes principais X1, X2, e X3 explicando respectivamente 9,92%, 6,49% e 5,02% da variância total dos dados.




Figura 4.26: Ilustração da distribuição dos dados mioelétricos para o grupo T60, composto pelos músculos músculos RF, VL, VML e VMO, com 9 voluntários, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 60% da CVIM, com as componentes principais X1, X2, e X3 explicando respectivamente 10,39%, 4,57% e 4,00% da variância total dos dados.




Figura 4.27: Ilustração da distribuição dos dados mioelétricos para o grupo T80, composto pelos músculos músculos RF, VL, VML e VMO, com 9 voluntários, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 80% da CVIM, com as componentes principais X1, X2, e X3 explicando respectivamente 5,25%, 4,47% e 4,01% da variância total dos dados.




Figura 4.28: Ilustração da distribuição dos dados mioelétricos para o grupo T100, composto pelos músculos RF, VL, VML e VMO, com 9 voluntários, considerando os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 100% da CVIM, com as componentes principais X1, X2, e X3 explicando respectivamente 5,24%, 3,98% e 3,32% da variância total dos dados.

A análise visual dos gráficos sugere um comportamento igualmente relevante para os quatro músculos, indicando que todos contribuem para o movimento fornecendo informações importantes para o estudo e a caracterização do torque exercido pelo quadríceps. Existe uma boa separabilidade entre os dados correspondentes a estes músculos, com regiões bem definidas para o espalhamento dos dados de cada grupo.

As 3 componentes principais utilizadas para projeção dos dados mostram que estes são pouco redundantes, ou seja, como estas são as componentes com a maior variância explicada para os dados estudados e têm valores situados entre 3,32% e 10,39%, então os grupos estudados possuem poucos dados supérfluos e necessitam de todas as componentes disponíveis para explicar as características do conjunto.

4.3.2 Taxa de reconhecimento para o classificador linear

Dado que as classes estudadas mostraram-se, aparentemente, linearmente separáveis, iniciaram-se os testes com um classificador linear calculando-se o PCA, utilizando-se o MLDA para melhorar a separabilidade entre-grupos e então empregando-se um classificador euclidiano simples de distância.

Para os cálculos com o classificador euclidiano a matriz de dados X , com 1080 x 17405 elementos, ou seja 5 níveis percentuais de torque (00nm foi retirado) x 4 músculos x 9 voluntários x 6 ângulos de posicionamento da perna, foi separada em 2 grupos, um grupo de treinamento para o classificador e um grupo de testes, correspondente à 20% da matriz X original, selecionado de forma aleatória. Este procedimento é conhecido na literatura afim como método de validação cruzada ou *cross-validation* [33]. Os cálculos foram realizados levando-se em conta todas as componentes principais disponíveis para cada matriz de dados. Para validação dos resultados foi estabelecido um total de cinco testes, aqui nomeados T1, T2, T3, T4 e T5. Assim, para o primeiro teste T1, temos uma matriz de treinamento X_1 com 870 x 17405 elementos, correspondentes a 5 classes com 174 amostras, e uma matriz de testes X_2 com 210 x 17405 elementos, correspondentes a 5 classes com 42 amostras. As tabelas 4.2 a 4.6 mostram respectivamente as taxas de classificação obtidas para as classes T20, T40, T60, T80 e T100, para cada grupo de treinamento, em seguida, as tabelas 4.8 a 4.12 mostram as taxas de classificação obtidas para as classes T20, T40, T60, T80 e T100, para os grupos de teste.

Resultados para o conjunto de treinamento utilizando o classificador linear

T1						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	174	0	0	0	0	100%
40%	0	174	0	0	0	100%
60%	0	0	174	1	1	100%
80%	3	0	0	171	0	98,27%
100%	0	0	0	0	174	100%

Tabela 4.2: Tabela de resultados para classificação do grupo T1 utilizando modelo linear.

T2						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	174	0	0	0	0	100%
40%	0	174	0	0	0	100%
60%	0	0	174	0	0	100%
80%	1	1	0	172	0	98,85%
100%	0	0	0	0	174	100%

Tabela 4.3: Tabela de resultados para classificação do grupo T2 utilizando modelo linear.

T3						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	174	0	0	0	0	100%
40%	0	174	0	0	0	100%
60%	0	0	174	0	0	100%
80%	2	0	0	172	0	98,85%
100%	0	0	0	0	174	100%

Tabela 4.4: Tabela de resultados para classificação do grupo T3 utilizando modelo linear.

T4						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	174	0	0	0	0	100%
40%	0	174	0	0	0	100%
60%	0	0	174	0	0	100%
80%	3	1	0	170	0	97,70%
100%	0	0	0	0	174	100%

Tabela 4.5: Tabela de resultados para classificação do grupo T4 utilizando modelo linear.

T5						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	174	0	0	0	0	100%
40%	0	174	0	0	0	100%
60%	0	0	174	0	0	100%
80%	2	0	0	172	0	98,85%
100%	1	0	0	0	173	99,42%

Tabela 4.6: Tabela de resultados para classificação do grupo T5 utilizando modelo linear.

Taxa de Classificação	
(% CVIM)	Taxa%
20%	100%
40%	100%
60%	100%
80%	98,50%
100%	99,88%

Tabela 4.7: Taxa média de classificação para as classes T20, T40, T60, T80 e T100 .

As tabelas 4.2, 4.3, 4.4, 4.5 e 4.6 mostram a classificação obtida para os conjuntos de treinamento T1, T2, T3, T4 e T5 respectivamente, com taxas de reconhecimento entre 97,70% e 100%. A tabela 4.7 traz as taxas médias de classificação obtidas individualmente para os grupos T1, T2, T3, T4 e T5. O resultado mostra as classes correspondentes a 20%, 40% e 60% do torque da CVIM com 100% de reconhecimento e as classes 80% e 100%, respectivamente com 98,50%, e 99,88%, confirmando ótimas taxas de reconhecimento do sinal EMG em todos os níveis percentuais de torque, com um pequeno desvio para as classes 80% e 100%.

Resultados para o conjunto de testes utilizando o classificador linear

T1						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	29	3	3	1	6	69,047%
40%	6	24	5	5	2	57,142%
60%	10	2	22	4	4	52,380%
80%	4	7	4	24	3	57,142%
100%	4	6	6	7	19	45,238%

Tabela 4.8: Tabela de resultados para classificação do grupo T1 utilizando modelo linear.

T2						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	24	9	3	4	2	57,142%
40%	8	18	5	3	8	42,871%
60%	10	6	15	8	3	35,714%
80%	9	3	5	17	8	40,476%
100%	6	9	5	5	17	40,476%

Tabela 4.9: Tabela de resultados para classificação do grupo T2 utilizando modelo linear.

T3						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	23	3	5	8	3	54,761%
40%	11	16	4	5	6	38,095%
60%	7	3	21	5	6	50%
80%	9	3	5	21	4	50%
100%	5	3	4	6	24	57,142%

Tabela 4.10: Tabela de resultados para classificação do grupo T3 utilizando modelo linear.

T4						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	25	5	0	6	6	59,523%
40%	9	23	3	4	3	54,761%
60%	7	8	22	3	2	52,380%
80%	9	6	3	20	4	47,619%
100%	14	5	3	5	15	35,714%

Tabela 4.11: Tabela de resultados para classificação do grupo T4 utilizando modelo linear.

T5						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	24	10	4	2	3	55,813%
40%	8	21	6	1	7	48,837%
60%	9	7	16	2	9	37,209%
80%	9	5	5	21	3	48,837%
100%	8	7	6	3	19	44,186%

Tabela 4.12: Tabela de resultados para classificação do grupo T5 utilizando modelo linear.

Taxa de Classificação	
(% CVIM)	Taxa%
20%	59,258%
40%	48,338%
60%	45,537%
80%	48,815%
100%	44,551%

Tabela 4.13: Cross-Validation para a taxa de classificação para as classes T20, T40, T60, T80 e T100 .

As tabelas 4.8, 4.9, 4.10, 4.11 e 4.12 mostram a classificação obtida para os conjuntos de treinamento T1, T2, T3, T4 e T5 respectivamente, com taxas de reconhecimento entre 37,209% e 69,047%. A tabela 4.13 traz as taxas médias de classificação obtidas individualmente para os grupos T1, T2, T3, T4 e T5. O resultado para o classificador linear mostra a classe correspondente a 20% do torque da CVIM com 59,258% de reconhecimento, a classe 40% com 48,338% e as classes 60%, 80% e 100%, respectivamente com 45,537%, 48,815% e 44,551%. Portanto o classificador mostrou uma taxa de reconhecimento do sinal EMG melhor para a classe 20%, e menor para a classe 100%.

4.3.3 Análise visual empregando um modelo não-linear para tratamento dos dados

Após a análise linear do sinal EMG, cuja taxa de classificação média ficou em torno de 100% e 49,29% para os conjuntos de treinamento e teste respectivamente, verificou-se a necessidade de empregarmos também um modelo não linear, para que fosse possível determinar se este modelo poderia explicar melhor o conjunto de dados correspondente aos sinais EMG, bem como apresentar uma taxa melhor para a classificação dos dados dos conjuntos de teste.

As figuras 4.29 e 4.30 ilustram, respectivamente, a matriz de dados X após transformação não-linear pelo KPCA e em seguida pelo KPCA seguido do MLDA.




Figura 4.29: Ilustração da distribuição dos dados mioelétricos para a matriz de dados X , no espaço tridimensional utilizando as 3 componentes principais de maior valor, após transformação não linear dos dados através do KPCA.




Figura 4.30: Ilustração da distribuição dos dados mioelétricos para a matriz de dados X , no espaço tridimensional utilizando as 3 componentes principais de maior valor, após transformação não linear dos dados através do KPCA mais o MLDA. É possível discriminar visualmente as áreas correspondentes as classes 20%, 40%, 60%, 80% e 100% do torque percentual aplicado.

De forma análoga ao processamento utilizando o modelo linear, o processamento visual não linear empregando apenas três componentes do KPCA também não traz informações que possibilitem distinguir quaisquer informações discriminantes para o conjunto dos dados na matriz X , como mostra a figura 4.29. Também de modo análogo, após a utilização do KPCA e do MLDA, torna-se possível identificar visualmente as regiões de interesse,

com as áreas correspondentes aos níveis de torque percentuais melhor definidas, entretanto com regiões mais compactas e apresentando uma sobreposição maior, quando comparadas ao modelo linear.

4.3.4 Taxa de Reconhecimento Para o classificador não-linear

Inicialmente realizou-se um teste para verificar o desempenho entre um classificador não linear, empregando o KPCA para tratamento dos dados com um classificador euclidiano, e um classificador não linear aplicando o KPCA e o MLDA para tratamento dos dados mais um classificador euclidiano. A figura 4.31 mostra o gráfico com o resultado dos valores de classificação alcançados por estes modelos, justificando assim a escolha do modelo não linear com MLDA para o tratamento dos conjuntos de dados e também o número de componentes principais utilizadas para os cálculos.

Como é possível observar pelo gráfico na figura 4.31, a matriz X de dados apresenta uma taxa melhor para classificação na medida em que aumenta-se o número de componentes principais utilizadas para o cálculo do classificador. Isso acontece em função da pouca redundância presente entre os dados que formam este conjunto.




Figura 4.31: Resultados para a classificação do conjunto referente a matriz X de dados, utilizando-se um classificador não -linear com e sem o MLDA para a etapa de tratamento dos dados.

As tabelas de dados utilizadas para os cálculos com o classificador não linear são as mesmas utilizadas para os cálculos com o classificador linear, com a mesma formação e

características, ou seja, a matriz de dados X é formada por 1080 x 17405 elementos e foi separada em um grupo para treinamento do classificador e outro para testes, correspondendo a 20% da matriz de dados X, selecionados de forma aleatória. Para a validação dos resultados obtidos, foram estabelecidos também 5 testes nomeados de T1 a T5, com a matriz de treinamento formada por 870 x 17405 elementos, e a matriz de testes com 210 x 17405 elementos.

As tabelas 4.14, 4.15, 4.16, 4.17 e 4.18 trazem respectivamente as taxas de classificação obtidas para o treinamento com os conjuntos 20%, 40%, 60%, 80% e 100% com um classificador não-linear.

Resultados para o conjunto de treinamento utilizando o classificador não linear

T1						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	174	0	0	0	0	100%
40%	1	173	0	0	0	99,42%
60%	0	0	174	0	0	100%
80%	2	0	0	172	0	98,85%
100%	0	0	0	0	174	100%

Tabela 4.14: Tabela de resultados para classificação do grupo T1 utilizando modelo não linear.

T2						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	174	0	0	0	0	100%
40%	1	173	0	0	0	99,42%
60%	0	0	174	0	0	100%
80%	0	0	0	174	0	100%
100%	0	0	0	0	174	100%

Tabela 4.15: Tabela de resultados para classificação do grupo T2 utilizando modelo não linear.

T3						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	174	0	0	0	0	100%
40%	0	174	0	0	0	100%
60%	0	0	174	0	0	100%
80%	2	0	0	172	0	98,85%
100%	0	0	0	0	174	100%

Tabela 4.16: Tabela de resultados para classificação do grupo T3 utilizando modelo não linear.

T4						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	174	0	0	0	0	100%
40%	2	172	0	0	0	98,85%
60%	0	0	174	0	0	100%
80%	2	0	0	172	0	98,85%
100%	0	0	0	0	174	100%

Tabela 4.17: Tabela de resultados para classificação do grupo T4 utilizando modelo não linear.

T5						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	173	1	0	0	0	99,42%
40%	6	168	0	0	0	96,55%
60%	2	0	172	0	0	98,85%
80%	2	0	172	0	0	98,85%
100%	0	0	1	1	172	98,85%

Tabela 4.18: Tabela de resultados para classificação do grupo T5 utilizando modelo não linear.

Taxa de Classificação	
(% CVIM)	Taxa%
20%	99,88%
40%	98,84%
60%	99,77%
80%	99,08%
100%	99,77%

Tabela 4.19: Taxas médias de classificação para as classes T20, T40, T60, T80 e T100 .

As tabelas 4.14, 4.15, 4.16, 4.17 e 4.18 mostram a classificação obtida para os conjuntos de treinamento T1, T2, T3, T4 e T5 respectivamente, com taxas de reconhecimento entre 96,55% e 100%. A tabela 4.19 traz as taxas médias de classificação obtidas individualmente para os grupos T1, T2, T3, T4 e T5. O resultado do grupo de treinamento para o classificador não linear mostra as classes correspondentes a 20%, 40%, 60%, 80% e 90% do torque da CVIM, com os respectivos valores de reconhecimento para o sinal EMG em torno de 99,88% 98,84% 99,77% 99,08% e 99,77%, ficando estes resultados ligeiramente abaixo do valor obtido pelo classificador linear.

Resultados para o conjunto de testes utilizando o classificador não-linear

As tabelas 4.20, 4.21, 4.22, 4.23 e 4.24 trazem respectivamente as taxas de classificação obtidas para os cinco testes executados.

T1						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	34	2	3	0	3	80,952%
40%	10	21	3	4	4	50%
60%	3	0	28	3	8	66,666%
80%	1	2	5	30	4	71,428%
100%	2	4	5	9	22	52,380%

Tabela 4.20: Tabela de resultados para classificação do grupo T1 utilizando modelo não linear.

T2						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	21	7	5	5	4	50%
40%	5	18	6	2	11	42,857%
60%	3	4	21	9	5	50%
80%	0	8	4	27	3	64,285%
100%	2	5	5	8	22	52,380%

Tabela 4.21: Tabela de resultados para classificação do grupo T2 utilizando modelo não linear.

T3						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	30	3	4	3	2	71,428%
40%	17	12	4	4	5	28,571%
60%	8	2	21	7	4	50%
80%	7	1	4	27	3	64,285%
100%	5	4	4	7	22	52,380%

Tabela 4.22: Tabela de resultados para classificação do grupo T3 utilizando modelo não linear.

T4						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	20	5	6	6	5	47,619%
40%	5	23	7	4	3	54,761%
60%	3	7	24	4	1	57,142%
80%	3	1	4	23	11	54,761%
100%	5	9	7	5	16	38,095%

Tabela 4.23: Tabela de resultados para classificação do grupo T4 utilizando modelo não linear.

T5						
(% CVIM)	20%	40%	60%	80%	100%	Taxa de Acerto
20%	23	9	5	2	3	54,761%
40%	9	23	4	3	3	54,761%
60%	10	7	19	0	6	45,238%
80%	4	9	5	17	7	40,476%
100%	2	0	4	0	36	85,714%

Tabela 4.24: Tabela de resultados para classificação do grupo T5 utilizando modelo não linear.

Taxa de Classificação	
(% CVIM)	Taxa%
20%	60,952%
40%	46,190%
60%	53,809%
80%	59,047%
100%	56,190%

Tabela 4.25: Taxas médias de classificação para as classes T20, T40, T60, T80 e T100 .

As tabelas 4.20, 4.21, 4.22, 4.23 e 4.24 mostram a classificação obtida para os conjuntos de treinamento T1, T2, T3, T4 e T5 respectivamente, com taxas de reconhecimento entre 28,571% e 85,714%. A figura 4.25 ilustra o gráfico comparativo para as taxas de classificação obtidas pelos classificadores linear e não linear para a matriz de dados X, considerando os grupos de treinamento. Pode-se observar um desempenho muito semelhante para os dois modelos de classificação, com pouca diferença na taxa de classificação, exceto pela discreta vantagem apresentada pelo modelo não linear para a classe correspondente a 80% da CVIM, com uma diferença que não chega a 1%.




Figura 4.32: Comparação da acuidade para as taxas de classificação utilizando um classificador linear e um não linear, para a matriz de dados X, considerando os grupos de treinamento, para ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 20%, 40%, 60% 80% e 100% da CVIM.

A figura 4.33 mostra o gráfico de comparação para as taxas de classificação obtidas pelos classificadores linear e não linear para a matriz de dados X, considerando os grupos de teste. Observa-se que, apesar do desempenho inicial, aparentemente superior, para a classe 20%, durante o testes T1, as taxas de classificação ficaram muito próximas para este grupo de dados em ambos os modelos. Isso acontece também para a classe 40%, que obteve uma classificação ligeiramente melhor no modelo linear. Para as demais classes, entretanto, o modelo não linear obteve uma taxa de classificação média expressivamente maior, com diferenças acima de 10%.




Figura 4.33: Comparação da acuidade para as taxas de classificação utilizando um classificador linear e um não linear, para a matriz de dados X, considerando os grupos de teste, para os ângulos 00°, 20°, 40°, 60°, 80° e 100°, a 20%, 40%, 60% 80% e 100% da CVIM.

4.4 Discussão

Muitos pesquisadores têm apresentado diferentes abordagens para a solução do problema de caracterização e reconhecimento do sinal mioelétrico nos últimos anos, grande parte deles baseados na utilização de técnicas de Inteligência Artificial, principalmente Redes Neurais, para a etapa de classificação dos sinais. O modelo comumente utilizado nas pesquisas para reconhecimento dos biopotenciais musculares prevê 5 etapas principais que vão desde a extração do sinal mioelétrico, passando pela formação das classes dos movimentos, a extração das características dos sinais estudados, a classificação destes sinais e, finalmente, a avaliação do erro. Estas técnicas buscam uma solução robusta para o problema de classificação do sinal mioelétrico e da supressão do ruído inerente a estes sinais. Contudo, as propostas que utilizam Redes Neurais ainda tentam superar as restrições impostas pelo tempo de processamento do conjunto de dados, que as tornam computacionalmente dispendiosas, e pelo conjunto de parâmetros que são estimados experimentalmente para sua implementação.

Inserido neste contexto, este trabalho procurou explorar o problema de extração de informações e de reconhecimento do sinal EMG, partindo de uma abordagem multivariada estatística, que permitiria a princípio o domínio e o melhor entendimento sobre os dados analisados em todas as etapas do seu processamento, explicando o comportamento linear ou não-linear dos grupos de dados estudados. A análise das componentes principais, ou PCA, foi escolhida como método inicial para extração das características dos conjuntos de dados estudados, destacando suas características principais e reduzindo sua dimensionalidade. Complementarmente, a análise de discriminantes lineares, regularizada através do método MLDA, foi investigada para melhorar a caracterização dos dados, através da maximização da separabilidade das suas classes, otimizando a caracterização dos dados que representam o torque isométrico do músculo quadríceps da coxa. Para efeito de comparação, um modelo estatístico multivariado não linear também foi utilizado. Uma vez que a relação *signal mioelétrico* x *torque isométrico* pode apresentar um comportamento não linear o KPCA foi escolhido como método para esta análise não linear. Por fim um classificador euclidiano foi utilizado para a etapa de classificação do sinal, possibilitando uma comparação do desempenho obtido pelos modelos de processamento linear e não linear.

A despeito das dificuldades impostas pela característica do sinal mioelétrico, sabida-

mente ruidoso[17, 15, 50], uma análise do sinal em seu estado natural, ou seja, sem que houvesse um processamento além do condicionamento inicial do sinal feito pelo sistema de aquisição, mostrou uma excelente separabilidade entre os grupos ou classes de interesse, o que sugere a contribuição de elementos presentes no sinal mioelétrico bruto, que talvez não estejam totalmente disponíveis ou se degradem em maior ou menor grau após um pós processamento. As figuras 4.34 e 4.35 mostram respectivamente a ilustração do sinal mioelétrico referente ao torque isométrico do músculo quadríceps da coxa, considerando todas as classes envolvidas, antes e após a extração do conjunto correspondente ao sinal mioelétrico referente ao nível percentual de torque 0Nm.

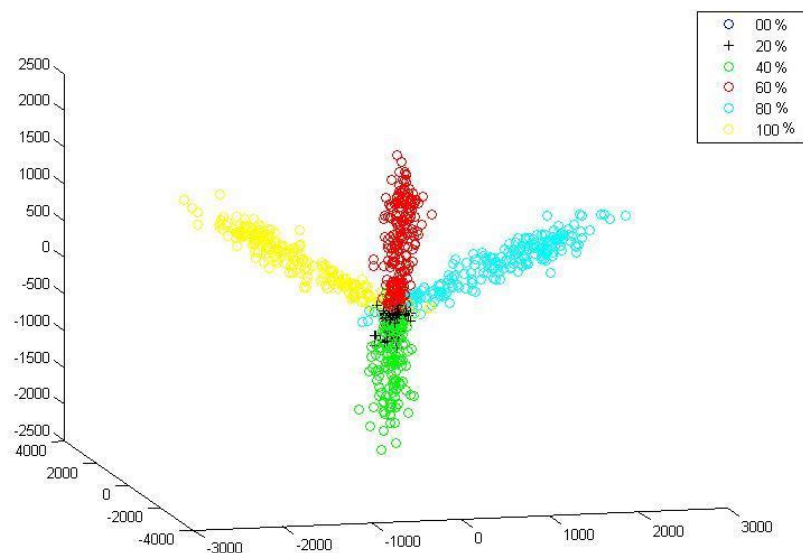


Figura 4.34: Análise visual do sinal mioelétrico bruto, antes da remoção do grupo correspondente a 0% da CVIM, no espaço tridimensional utilizando as 3 componentes principais de maior valor. No centro da figura pode-se perceber a classe correspondente ao nível percentual de torque aplicado 0%, sobreposto aos demais conjuntos.




Figura 4.35: Análise visual do sinal mioelétrico bruto, após a remoção do grupo correspondente a 0% da CVIM, no espaço tridimensional utilizando as 3 componentes principais de maior valor. Percebe-se que após a remoção do conjunto correspondente a 0% da CVIM, houve uma melhora visual na separabilidade dos demais conjuntos.

Observa-se nas Figuras acima, uma sensível melhora após a remoção da classe correspondente a 0% da CVIM, indicando que este grupo funcionava como ruído, pois influenciava a discriminação das demais classes. As figuras 4.36 e 4.37 mostram respectivamente o espalhamento dos dados correspondentes ao sinal mioelétrico referente ao torque isométrico do músculo quadríceps da coxa, considerando todas as classes envolvidas, após um pós tratamento simples, considerando apenas a inversão da porção negativa do sinal mioelétrico, e novamente sem o pós processamento.




Figura 4.36: Análise visual do sinal mioelétrico bruto, no espaço tridimensional utilizando as 3 componentes principais de maior valor, após a inversão da parte negativa do sinal EMG.




Figura 4.37: Análise visual do sinal mioelétrico bruto, no espaço tridimensional utilizando as 3 componentes principais de maior valor, considerando toda a informação disponível, sem um pós processamento.

Percebe-se que, visualmente, não houve uma melhora na separação das classes. Esta observação incentivou a continuidade dos experimentos utilizando o sinal em seu estado natural.

Apesar da análise visual da matriz de dados X sugerir uma excelente separabilidade das classes que a compõem, as taxas médias de classificação obtidas pelos modelos linear e não linear, para os grupos de teste, foram de 49,29% e 55,23% respectivamente. Entretanto, algumas classificações parciais obtiveram taxas de reconhecimento do sinal EMG

acima dos 80%, considerando 5 classes possíveis, ou seja, uma esperança estatística de 20% para cada classe. Para os grupos de treinamento, entretanto, os valores de classificação obtiveram resultados ainda mais expressivos, com taxas médias de classificação do sinal EMG em torno de 99,4% e 99,6% respectivamente. Este resultado sugere que a classificação dos grupos de teste ficou limitada pela disponibilidade de poucas amostras.

Estes resultados confirmam que o reconhecimento do sinal mioelétrico pode ser melhorado através da utilização da análise estatística multivariada para tratar conjuntos altamente dimensionais e com uma quantidade limitada de amostras.

Capítulo 5

Conclusão e Trabalhos Futuros

A aquisição de sinais mioelétricos através de eletrodos superficiais não invasivos, ligados diretamente à pele, implica ter que lidar com um conjunto de dados altamente suscetível a ruídos e muitas vezes redundantes, em função das variações elétricas da pele, do deslocamento dos eletrodos, variações bioquímicas e das variações na morfologia muscular e tecidual de cada indivíduo.

Estudar o sinal EMG, na tentativa de caracterizá-lo extraindo informações úteis a partir dos dados registrados, mostrou-se uma tarefa desafiadora cientificamente. Os resultados experimentais evidenciaram que a utilização de modelos estatísticos, baseados em transformações lineares, podem viabilizar a manipulação desses conjuntos n -dimensionais, facilitando a sua análise.

Considerando o torque isométrico do músculo quadríceps da coxa e os dados disponíveis para os experimentos realizados neste trabalho, foi possível, através da análise de discriminantes lineares e do KPCA, caracterizar o sinal mioelétrico para esse conjunto de dados, constatando que sinais mioelétricos do músculo quadríceps da coxa provenientes de movimentos isométricos da perna, mesmo quando executados em ângulos diferentes, mas com o mesmo nível percentual de torque, apresentam características determinísticas similares. Com base nessa premissa, foi possível classificar os sinais mioelétricos correspondentes aos níveis percentuais de torque da CVIM, independentemente do ângulo na qual se posicionava a perna ou do músculo em questão.

A proposta feita nesse trabalho para a caracterização dos sinais mioelétricos corres-

pondentes ao torque isométrico do músculo quadríceps da coxa, através da utilização de métodos estatísticos multivariados, obteve resultados positivos quanto à discriminação e classificação do sinal, o que corrobora a hipótese de que este sinal pode imprimir uma assinatura única, através de informações tais como a quantidade de unidades motoras recrutadas para a tarefa de gerar força, a taxa de disparo dessas unidades em função do tempo, da força aplicada e da amplitude do sinal.

As taxas de classificação alcançadas sugerem que existe uma limitação em função da quantidade de amostras disponíveis para a etapa de treinamento do modelo estatístico. A utilização de um modelo não linear melhorou essa classificação, indicando que este pode ser o modelo ideal para o tratamento desses dados, ainda que testes utilizando outros métodos sejam necessários.

5.1 Trabalhos Futuros

A pesquisa atual abordou os aspectos técnicos da captação do sinal EMG, identificou as classes de movimentos existentes na base de dados disponível formando os conjuntos ou grupos estudados e efetuou a extração das características, o reconhecimento e a classificação dos sinais mioelétricos que representam o torque isométrico do músculo quadríceps da coxa, além de utilizar também um modelo estatístico não linear para tratamento dos conjuntos de dados.

Os trabalhos futuros incluem a implementação de um modelo baseado em Redes Neurais, para comparação dos resultados, além do tratamento de informações que não puderam, por indisponibilidade de tempo, ser tratadas nesse trabalho, tais como:

- O estudo mais aprofundado quanto a participação individual dos músculos que compõem o músculo quadríceps da coxa, durante o torque isométrico da perna;
- Investigar se as características discriminantes do sinal mioelétrico são afetadas pela composição do grupo de voluntários, divididos entre homens e mulheres;
- Utilizar os sinais dos grupos agonista e antagonista, somados, para o processamento com o modelo estatístico multivariado linear e não linear.

Referências Bibliográficas

- [1] Cichocki A. and Unbehauen R. *Neural networks for optimization and signal processing*. New York: John Wiley, 1993.
- [2] Daffertshofer A., Lamoth C. J. C., Meijer O. G., and Beek P. J. Pca in studying coordination and variability: a tutorial. *Clinical Biomechanics*, 19:415–428, January 2004.
- [3] Howard A. and Rorres C. *Elementary Linear Algebra*. Jonh Wiley Sons, Inc., 9^a edition, 2005.
- [4] Rencher A. C. *Methods of Multivariate Analysis*. Jonh Wiley Sons, Inc., 2002.
- [5] Boca A. D. and Park D. E. Myoelectric signal reconation using fuzzy clustering and artificial neural networks in real time. *IEEE International Conference on Neural Networks and IEEE World Congress on Computational Inteligence 1994*, 5:3098–3103, 1994.
- [6] Arieta A. H., Katoh R., Yokoi H., and Wenwei Y. Development of a multi-dof electromyography prosthetic system using the adaptative joint mechanism. *Applied Bionics and Biomechanics*, 3(2):101–112, June 2006.
- [7] Izenman A. J. *Modern Multivariate Statistical Techniques*. Springer, 2008.
- [8] Hudgins B., Parker P., and Scott R. N. A new strategy for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*, 40(1):82–94, January 1993.
- [9] Choi C., Kwon S., Park W., Shin M., and Kim J. Real-time isometric pinch force prediction from semg. *IEEE/RAS-EMBS International Conference on Biomedical Robotics and Biomechatronics*, October 2008.

- [10] Thomaz C. E. Estudo de classificadores para o reconhecimento automático de faces. Master's thesis, Department of Electrical Engineering, PUC/RJ, Abril 1999. 1999.
- [11] Thomaz C. E. *Maximum Entropy Covariance Estimate for Statistical Pattern Recognition*. PhD Thesis - Imperial College London, 2004.
- [12] Thomaz C. E., Kitani E. C., and Gillies D. F. A maximum uncertainty lda-based approach for limited sample size problems - with application to face recognition. *Journal of the Brazilian Computer Society*, 12(2):7–18, 2006.
- [13] Thomaz C. E. and Giraldo G. A. A kernel maximum uncertainty discriminant analysis and its application to face recognition. *International Conference on Computer Vision Theory and Applications VISAPP09*, pages 341–346, 2009. Lisboa, Portugal.
- [14] De Luca C. J. Physiology and mathematics of myoelectric signals. *IEEE Transaction on Biomedical Engineering*, (26):313–325, 1979.
- [15] De Luca C. J. Surface electromyography: Detection and recording. *Delsys Incorporated*, 2002.
- [16] De Luca C. J. Electromyography. *Enciclopedia of Medical Devices and Instrumentation*, pages 64–101, 2006.
- [17] De Luca C.J. The use of surface electromyography in biomechanics. *Journal of Applied Biomechanics*, 13(2):135–63, 1997.
- [18] Staudenmann D., Roeleveld K., Stegeman D. F., and Dieën J. H. van. Methodological aspects of semg recordings for force estimation - a tutorial and review. *Journal of Electromyography and Kinesiology*, (20):375–387, 2010.
- [19] Kitani E.C. and Thomaz C.E. Um tutorial sobre análise de componentes principais para o reconhecimento automático de faces. Technical report, Departamento de Engenharia Elétrica-Centro Universitário da FEI, Av. Humberto Alencar de Castelo Branco, 3972 SBC-SP-Brasil, 2006.
- [20] Nelwamondo F.V. and Marwala T. Fuzzy artmap and neural network approach to online processing of inputs with missing values.
- [21] Carpenter G. A., Grossberg S., Markuzon N., Reynolds J. H., and Rosen D. B. Fuzzy artmap: A neural network architecture for incremental supervised lear-

- nig of analog multidimensional maps. *IEEE Transaction on Neural Networks*, 3(5):698–712, 1992.
- [22] Giraldi G. A., Rodrigues P. S., Kitani E. C., and Thomaz C. E. Dimensionality reduction, classification and reconstruction problems in statistical learning. *Revista de Informatica Teorica e Aplicada (RITA), Special Issue on SIBGRAPI'07 Tutorials*, 15(1):141–173, 2008.
- [23] Silva G. A. da, Castro M. C. F., and Thomaz C. E. A multivariate statistical analysis of muscular biopotencial for human arm movement characterization. *International Conference on Bio-inspired Systems and Signal Processing, BIO-SIGNALS 2009*, pages 227–232, 14-17th January 2009.
- [24] J. Hefferon. *Linear Algebra*. Virginia Commonwealth University Mathematics, 2009.
- [25] <http://www.forp.usp.br/restauradora/oclusao/lapese>. Breve histórico sobre eletromiografia. Acessado em 15/02/2009.
- [26] Jolliffe I.T. *Principal Component Analysis, 2^o Edition*. Springer, 175 Fifth Avenue, New York, NY 10010, USA, 2002.
- [27] Shlens J. A tutorial on principal component analysis. December 2005. Systems Neurobiology Laboratory, Salk Institute for Biological Studies, La Jolla, CA 92037 and Institute for Non Linear Science, University of California, San Diego, La Jolla, CA 92093-0402.
- [28] Tan J., Yang R., and Kafatos M. Kernel pca analysis for remote sensing data. *18th Conference on Climate Variability and Change*, 2006.
- [29] Yang J., Frangi A. F., Jing yu Yang, Zhang D., IEEE, and Jin Z. Kpca plus lda: A complete discriminant framework for feature extraction and recognition. *IEE Transactions on Pattern Analysis and Machine Intelligence*, 27(2):230–244, 2005.
- [30] Neto J. M. M. and Moita G. C. Uma introdução à análise exploratória de dados multi-variados. *Química Nova*, 21:467–469, Abril 1998.
- [31] Magnus J. R. and Neudecker H. *Matrix Differential Calculus with Applications in Statistics and Econometrics*. Chichester: John Wiley Sons Ltd., revised edition edition, 1999.

- [32] Hogrel J. Y., Ledoux I., and Duchêne J. Reliability of muscle fibre conduction velocity distribution estimation from surface emg. *Science Direct - Biomedical Signal Processing and Control*, pages 118–125, 2008.
- [33] Fukunaga K. *Introduction to statistical pattern recognition*. Academic Press, Boston, 2 edition, 1990.
- [34] Henneberg K. Principles of electromyography. In Joseph D. Bronzino, editor, *The Biomedical Engineering Handbook*, chapter 14, pages 178–187. CRC Press LLC, 2000.
- [35] Nazarpour K, Sharafat A.R., and Firoozabadi S.M. A novel feature extraction scheme for myoelectric signals classification using high order statistics. *2nd International IEEE EMBS Conference*, pages 293–296, March 2005.
- [36] Galvani L. De viribus aelectricitatis in motu musculari. 1791. Universidade de Bolonha - Itália.
- [37] Mesin L., Kandoor A.K.R., and Merletti R. Separation of propagating and non propagating components in surface emg. *Science Direct - Biomedical Signal Processing and Control*, pages 126–137, 2008.
- [38] Elias L.A., Vieira M.F., Pacheco C.C.A.C., Moreira L.S., Rodrigues F.B., and Abadia F.G. Relação entre a força de extensão do joelho e a atividade mioelétrica dos componentes do quadríceps. *21º Congresso Brasileiro de Engenharia Biomédica*.
- [39] Peters M. Footedness: asymmetries in foot preference and skill and neuropsychological assessment of foot movement. *Psychol Bull* 103, pages 5179–192, 1998.
- [40] Vuskovic M. and Sijiang Du. Classification of prehensile emg patterns with simplified fuzzy artmap network.
- [41] Lebedev M. A., O’Doherty J. E., and Nicolelis M. A.L. Decoding of temporal intervals from cortical ensemble activity. *Journal of Neurophysiology*, 11(99), 2008.
- [42] Lebedev M. A. and Nicolelis M. A.L. Brain-machine interfaces: past, present and future. *Science Direct*, 29(9), 2006.

- [43] Rosário M. F. 120 anos do nascimento do cientista r. a. fisher (1890-2010). *Rev. Bra. Biom.*, 27(4):659–627, 2010.
- [44] Reaz M.B.I., Hussain M.S., and Mohd-Yasin F. Techniques of emg signal analysis: detection, processing, classification and applications. *Biol. Proced. Online* 2006, 8(1):11–35, March 2006.
- [45] Belluck P. Braço artificial aprende a escutar o cérebro. *The New York Times*, page 5, Fev. 2009.
- [46] Bornato P., de Alessio T., and Knafitz M. A statistical method for the muscle activation intervals from surface myoelectric signal gait. *IEEE Trans Biomed Eng* 1998, 45:287–299, 1998.
- [47] Devijver P. A. and Kittler J. *Pattern Classification: A Statistical Approach*. Prentice-Hall, Englewood Cliffs, N. J., 1982.
- [48] Ambrósio P. E. and Silva M.V. Rede neural fuzzy artmap para classificação de lesões pulmonares. *21º Congresso Brasileiro de Engenharia Biomédica*, pages 1015–1017.
- [49] Franciulli P. M. Análise da relação entre parâmetros eletromiográficos e o torque isométrico do músculo quadríceps da coxa. Master's thesis, Universidade São Judas Tadeu, Prof. Dr. Rubens Correa Araújo, 2006.
- [50] Araújo R. C. *Utilização da Eletromiografia na Análise Biomecânica do Movimento Humano*. PhD thesis, Universidade de São Paulo, Escola de Educação Física e Esporte da Universidade de São Paulo, São Paulo - SP, 1998.
- [51] Kleissen R.F.M., Buurke J.H., Harlaar J., and Zivold G. Electromyography in the biomechanical analysis of human movement and its clinical application. *Gait and Posture*, 8:143–158, June 1998.
- [52] Micera S., Sabatini A.M., Dario P., and Rossi B. A hybrid approach to emg pattern analysis for classification of arm movements using statistical and fuzzy techniques. *Medical Engineering Physics*, (21):303–311, 1999.
- [53] Haykin S. S. *Neural Networks: a comprehensive foundation*. Prentice Hall, 2nd edition edition, 1999.

- [54] Johnson S.W., Lynn P.A., Miller J.S.G., and Reed G.A.L. Miniature skin-mounted preamplifier for measurement of surface electromyographic potentials. *Medical and Biological Engineering Computation*, (5):698–712, 1977.
- [55] Sinkjaer T., Toft E., Larsen K., and Andreassen S. Emg-torque dynamics at different contraction levels in human ankle muscles. *Journal of Electromyography and Kinesiology*, 3(2):67–77, 1993.
- [56] Arabadzhiev T.I., Dimitrov G.V., Dimitrov A.G., Chakarov V.E., and Dimitrova N.A. Factors affecting the turns analysis of the interference emg signal. *Science Direct - Biomedical Signal Processing and Control*, pages 145–153, 2008.
- [57] Lanyi X. and Adler A. An improved method for muscle activation detection during gait. *Canadian Conference of Electrical and Computer Engineering 2004*, 1:357–360, 2004.