



**METODOLOGIAS DE ESTIMAÇÃO DO ÂNGULO DO JOELHO  
PARA DETECÇÃO DA INTENÇÃO DE MOVIMENTO**

**ALBERTO LÓPEZ DELIS**

**TESE DE DOUTORADO EM ENGENHARIA ELÉTRICA**

**DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**FACULDADE DE TECNOLOGIA**

**UNIVERSIDADE DE BRASÍLIA**

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

**METODOLOGIAS DE ESTIMAÇÃO DO ÂNGULO DO  
JOELHO PARA DETECÇÃO DA INTENÇÃO DE  
MOVIMENTO**

**ALBERTO LÓPEZ DELIS**

**ORIENTADORES: GEOVANY ARAUJO BORGES  
ADSON FERREIRA DA ROCHA**

**TESE DE DOUTORADO EM ENGENHARIA ELÉTRICA**

**PUBLICAÇÃO: PPGENE.TD – 049/10**

**BRASÍLIA/DF: MARÇO – 2010**

## **FICHA CATALOGRÁFICA**

DELIS, ALBERTO LÓPEZ

Metodologias de estimação do ângulo do joelho para detecção da intenção de movimento [Distrito Federal] 2010.

xvii, 151p., 210 x 297 mm (ENE/FT/UnB, Doutor, Tese de Doutorado – Universidade de Brasília. Faculdade de Tecnologia.

Departamento de Engenharia Elétrica

1. Sinal Mioelétrico de Superfície

2. Fusão de dados

3. Prótese de perna

4. Algoritmo Mioelétrico

I. ENE/FT/UnB

II. Título (série)

## **REFERÊNCIA BIBLIOGRÁFICA**

DELIS, A. L. (2010). Metodologias de estimação do ângulo do joelho para detecção da intenção de movimento. Tese de Doutorado em Engenharia Elétrica, Publicação PPGENE.TD-049/10, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília, DF, 151p.

## ***CESSÃO DE DIREITOS***

AUTOR: Alberto López Delis.

TÍTULO: Metodologias de estimação do ângulo do joelho para detecção da intenção de movimento.

GRAU: Doutor

ANO: 2010

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

---

Alberto López Delis  
SQN 405, Bloco D, Apto. 105, Asa Norte  
70846-040 Brasília – DF – Brasil.

## **AGRADECIMENTOS**

Agradeço a meus pais por sua grandeza, por sua formação, por sua luta e constância que fizeram de mim um homem de bem para minha família e para a sociedade.

Agradeço a meu prezado filho Angel Alberto que todos os dias durante os quatro anos de meu doutorado me transmitiu força para seguir adiante e lutar por ele e seu futuro. Agradeço a minha esposa que desde o momento em que a conheci, minha vida mudou completamente, trazendo-me momentos muito felizes. Eles são o motor impulsor de minha vida.

Agradeço a meus prezados irmãos e a toda minha família.

Agradeço aos mentores espirituais (Virgem da Caridade) que me guiam e inspiram nessa jornada terrena. À memória de meus tios e avós falecidos.

Agradeço à CNPq, CAPES e FUB pelo financiamento deste trabalho.

Agradeço a minha instituição, Centro de Biofísica Médica, por depositar a confiança em mi para realizar o doutorado.

Agradeço a meus orientadores Dr. Adson Ferreira da Rocha e Dr. Geovany Araujo Borges por acreditarem em mi e na concepção do projeto, por suas idéas, pelo apoio em minha formação acadêmica. Agradeço ao professor Adson pela dedicação, humanidade e amizade.

Agradeço ao Dr. João Luiz Carvalho pelo apoio em meu projeto de doutorado, pela experiência e sugestões que contribuíram com o aumento da qualidade do trabalho.

Agradeço inmesamente aos amigos do Centro de Biofísica Médica e da Universidade de Oriente; Alcibiades, Alexander Pascau, Alexander Soñora, Carlos, Caridad Mendez, Caridad Paz, Denis, Domingo, Erlín, Fabars, Ernesto, Juan Carlos, Marielena, Manuel Cuadra, Manuel Lores, Oreste, Raudel e Yaritza por transmitirem energias positivas e

acreditarem em mim, na continuidade e na conclusão deste projeto. Por serem parte de minha formação como pesquisador.

Agradeço inmesamente aos amigos de Brasília; Alexander Zagheto, Alexander Franco, Bruno, Camilo, Caue, Diogo, Edson, Eduardo, Fabiano, Fabrício, Fernanda, Filomeno, Guilmar, Karen, Jorge, María do Carmo, Marcelo, Marcelino, Marcos, Pablo, Rafael, Renam, Sonia, Suelia, Tiago e Yovanka por seu apoio, por terem me ajudado nesse período em que estive longe de minha família e por terem feito sentir-me como em minha casa durante os quatro anos que compartilhei com eles. Eles sempre ocuparão um espaço em meu coração.

Se pensas que estás vencido, estás. Se pensas que não te atreves, não farás. Se pensas que gostarias de ganhar, mas não podes, não lograrás. Se pensas que perderás já perdeste, porque descobrirás que no mundo todo o sucesso começa com o pensamento do homem, tudo está em seu estado mental. Muitas corridas foram perdidas antes de se haver corrido e muitos covardes fracassaram antes de haverem empreendido seu trabalho. Pensas no grande e teus direitos crescerão, pensa em pequeno e ficarás atrás, pensas que podes e poderás, tudo está em teu estado mental. Se pensas que estas com vantagem, estás, tens que pensar bem para te elevares, tens que estar seguro de ti mesmo antes de procurar ganhar um prêmio. A batalha da vida nem sempre a ganha o homem mais forte ou o mais ligeiro, porque tarde ou cedo, o homem que ganha é aquele que acredita poder fazer-lo.

*Cristian Bernard*

## **RESUMO**

### **METODOLOGIAS DE ESTIMAÇÃO DO ÂNGULO DO JOELHO PARA DETECÇÃO DA INTENÇÃO DE MOVIMENTO**

**Autor: Alberto López Delis**

**Orientador: Geovany Araujo Borges**

**Co-Orientador: Adson Ferreira da Rocha**

**Programa de Pós-graduação em Engenharia Elétrica**

**Brasília, mês de Março (2010)**

O sinal mioelétrico de superfície pode ser utilizado de maneira eficaz para detectar a intenção de movimento no controle de próteses mecânicas. Quando se trata da concepção de um projeto que utiliza o controle mioelétrico, a implementação de um algoritmo que utiliza tal técnica é de fundamental importância. Este trabalho propõe dois algoritmos de estimação do ângulo do joelho para detectar a intenção de movimento em uma prótese de perna. A primeira proposta usa como dados a informação extraída a partir de dois canais de eletromiografia e um canal para eletrogoniômetro. A informação é processada por meio de três estágios: (1) extração de características utilizando modelos auto-regressivos e histograma; (2) projeção de características por meio de mapas auto-organizáveis e (3) classificação de padrões usando rede neural perceptron multicamada. A segunda proposta de algoritmo usa a informação extraída a partir de sensores giroscópios como dados adicionais à primeira proposta. A informação é processada por meio de três estágios: (1) extração de características utilizando coeficientes cepstrais e a entropia no sinal mioelétrico, (2) classificação de padrões usando rede neural perceptron multicamada e (3) fusão de dados a partir do filtro de *Kalman*, utilizando três variantes para a estimação do ângulo do joelho. A plataforma experimental desenvolvida é um sistema micro-controlado para a aquisição e pré-processamento dos sinais mioelétricos em tempo real. É apresentada uma comparação quantitativa entre os algoritmos propostos, o método de Ferreira *et al.* e o método *wavelet packets* – análise de componentes principais, baseada em indicadores como percentual erro-sinal, coeficiente de correlação e número, amplitude e duração do erro. Os resultados obtidos demonstram que é possível estimar continuamente a posição do ângulo do joelho a partir dos sinais mioelétricos e sua fusão com sensores proprioceptivos.

## **ABSTRACT**

### **METODOLOGY FOR ESTIMATION OF KNEE ANGLE FOR DETECTION MOTION INTENTION**

**Author: Alberto López Delis**

**Academic Supervisors: Geovany Araujo Borges**

**Adson Ferreira da Rocha**

**Graduate Program in Electrical Engineering**

**Brasília, March of 2010**

The myoelectric signal can be used in an effective way for detecting motion intention in order to control mechanical prostheses. In the design and implementation of a myoelectric controller, the implementation of the myoelectric algorithm is very important. This work proposes two algorithms to estimate knee angle to detect motion intention in leg prostheses. The first algorithm uses the information extracted from two electromyography (EMG) channels and one electrogoniometer channel. This information is processed through three stages: (1) feature extraction using auto-regressive models and histogram, (2) feature projections through self-organizing maps and (3) pattern classification using a perceptron neural network. The second algorithm uses information from gyroscopic sensors as additional data. This information is processed through three stages: (1) feature extraction using cepstral coefficients and the myoelectric signal entropy, (2) pattern classification using a perceptron neural network and (3) data fusion from kalman filter using three variant for knee angle estimation. A micro-controlled bioinstrumentation system has been developed for the acquisition and pre-processing of the electromyographic signal in real-time. A quantitative comparison between the proposed algorithms, the method by Ferreira *et al.* and the *wavelet packet* – principal components analysis are presented, based on several metrics such as the error-to-signal percentage (ESP), the correlation coefficients, and the number, amplitude and duration of error events. The results demonstrate that it is possible to estimate continuously the knee angle from mioelectric signals and their fusion with proprioceptive sensors.



# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO.....</b>	<b>1</b>
1.1	SINAIS MIOELÉTRICOS NA DETECÇÃO DE INTENÇÃO DE MOVIMENTO.....	2
1.2	PROBLEMA DA PESQUISA.....	4
1.3	OBJETIVOS DO TRABALHO.....	6
1.4	HIPÓTESES DO TRABALHO.....	7
1.5	JUSTIFICATIVA DO TRABALHO.....	7
1.6	ESTRUTURA DO DOCUMENTO.....	9
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA.....</b>	<b>10</b>
2.1	O PROCESSO DE CONTRAÇÃO MUSCULAR.....	10
2.2	O SINAL MIOELÉTRICO.....	12
2.3	CAPTAÇÃO E CONDICIONAMENTO DO SINAL MIOELÉTRICO.....	13
2.4	INTERFERÊNCIA NO SINAL MIOELÉTRICO.....	16
2.5	DIGITALIZAÇÃO DOS SINAIS MIOELÉTRICOS.....	17
2.6	USO DOS SINAIS MIOELÉTRICOS EM PRÓTESES ATIVAS.....	18
2.6.1	O problema da classificação de padrões mioelétricos.....	19
2.6.2	A segmentação dos dados.....	21
2.6.3	Extração de características.....	23
2.6.3.1	Análise no domínio do tempo.....	24
2.6.3.2	Análise no domínio da frequência (análise espectral).....	30
2.6.3.3	Análise tempo-escala.....	33
2.6.3.4	Análises fenomenológicas.....	35
2.6.4	Índices de desempenho quantitativo do espaço característico.....	37
2.6.5	Classificação do espaço característico.....	40
2.6.5.1	Enfoque em redes neurais.....	40
2.6.5.2	Enfoque por lógica nebulosa.....	41
2.6.5.3	Enfoque Neuro- <i>fuzzy</i> .....	42
2.6.5.4	Enfoque probabilístico.....	43
2.6.5.5	Enfoque com máquina de vetores suportados.....	44
2.6.5.6	Treinamento <i>online</i> .....	46

2.6.6 – Fusão de dados em algoritmos mioelétricos.....	47
2.7 – CONCLUSÃO DO CAPÍTULO.....	49
<b>3 – BIOINSTRUMENTAÇÃO E PROTOCOLO EXPERIMENTAL.....</b>	<b>52</b>
<b>3.1 – ESTRUTURA DO BLOCO DE BIOINSTRUMENTAÇÃO PARA SINAIS</b>	
<b>MIOELÉTRICOS.....</b>	<b>53</b>
3.1.1 – Implementação do filtrado adaptativo.....	56
3.2 – MÓDULO DE SOFTWARE PARA COLETA DOS DADOS.....	58
3.3 – PROTOCOLOS EXPERIMENTAIS.....	61
3.3.1 – Implementação do protocolo experimental #1.....	62
3.3.2 – Implementação do protocolo experimental #2.....	65
3.4 – CONCLUSÃO DO CAPÍTULO.....	68
<b>4 – ALGORITMOS MIOELÉTRICOS DE ESTIMAÇÃO CONTÍNUA.....</b>	<b>70</b>
<b>4.1 – PRIMEIRA PROPOSTA DE ALGORITMO PARA ESTIMAÇÃO DO</b>	
<b>ÂNGULO DO JOELHO UTILIZANDO SINAIS MIOELÉTRICOS.....</b>	<b>70</b>
4.1.1 – Extração de características.....	75
4.1.2 – Projeção de características.....	77
4.1.3 – Classificação dos padrões mioelétricos.....	78
4.1.4 – Esquema geral de funcionamento e configuração dos parâmetros para o	
algoritmo mioelétrico.....	81
<b>4.2 – SEGUNDA PROPOSTA DE ALGORITMOS DE ESTIMAÇÃO DO</b>	
<b>ÂNGULO DE JOELHO UTILIZANDO FUSÃO DE DADOS ENTRE SINAIS</b>	
<b>MIOELÉTRICOS E SENSORES PROPRIOCEPTIVOS.....</b>	<b>82</b>
4.2.1 – Extração de características.....	84
4.2.2 – Classificação dos padrões mioelétricos.....	85
4.2.3 – Filtragem estocástica na medida de velocidade angular e correção na	
estimação do ângulo.....	86
4.2.3.1 – Primeira variante de fusão de dados.....	87
4.2.3.2 – Segunda variante de fusão de dados.....	88
4.2.3.3 – Terceira variante de fusão de dados.....	90
4.2.4 – Configuração dos parâmetros para as variantes dos algoritmos	
mioelétricos.....	92
4.3 – CONCLUSÃO DO CAPÍTULO.....	93

<b>5 – RESULTADOS E DISCUSSÃO.....</b>	<b>96</b>
<b>5.1 – ESTIMAÇÃO DO ÂNGULO PARA A PRIMEIRA PROPOSTA DE ALGORITMO.....</b>	<b>96</b>
<b>5.2 – ESTIMAÇÃO DO ÂNGULO PARA A SEGUNDA PROPOSTA DE ALGORITMO.....</b>	<b>97</b>
<b>5.3 – ERRO MÉDIO QUADRÁTICO E NÚMERO DE PADRÕES DE ENTRADA.....</b>	<b>98</b>
<b>5.4 – COMPARAÇÃO COM OUTRAS VARIANTES DE ALGORITMOS MIOELÉTRICOS.....</b>	<b>99</b>
<b>5.4.1 – Métricas estatísticas de comparação.....</b>	<b>101</b>
<b>5.4.2 – Determinação da significância estatística.....</b>	<b>103</b>
<b>5.4.3 – Resultados da comparação para a primeira proposta de algoritmo mioelétrico.....</b>	<b>104</b>
<b>5.4.4 – Resultados da comparação para a segunda proposta de algoritmo mioelétrico.....</b>	<b>108</b>
<b>5.5 – CONCLUSÃO DO CAPÍTULO.....</b>	<b>121</b>
<b>6 – CONCLUSÕES.....</b>	<b>122</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>128</b>
<b>APÊNDICE.....</b>	<b>139</b>
<b>A– ZONAS DE ESTUDO UTILIZADAS DURANTE A IMPLEMENTAÇÃO DO SEGUNDO PROTOCOLO EXPERIMENTAL NOS MÚSCULOS AGONISTAS E ANTAGONISTAS.....</b>	<b>140</b>
<b>B– SINAIS OBTIDOS DURANTE O PROTOCOLO EXPERIMENTAL NOS DOZE VOLUNTÁRIOS.....</b>	<b>142</b>
<b>C– TERMO DE LIVRE CONSETIMENTO E ESCLARECIDO. CERTIFICADO DE ACEITAÇÃO DO PROTOCOLO EXPERIMENTAL SUBMETIDO AO COMITÊ DE ÉTICA EM PESQUISA DA UNB.....</b>	<b>145</b>
<b>D– DESCRIÇÃO DO CD.....</b>	<b>148</b>
<b>E– DIAGRAMAS ESQUEMÁTICOS DO SISTEMA DE BIOINSTRUMENTAÇÃO.....</b>	<b>149</b>

## LISTA DE TABELAS

Tabela 3.1 - Características de estudo para os sujeitos correspondentes ao protocolo experimental #1.....	63
Tabela 3.2 - Características de estudo para os sujeitos correspondentes ao protocolo experimental #2.....	67
Tabela 5.1 - Comparação entre os algoritmos baseados no percentual erro–sinal (algoritmo Ferreira <i>et al.</i> , (2005), algoritmo EWP–PCA e primeira proposta de algoritmo).....	104
Tabela 5.2 - Comparação entre os algoritmos baseados no coeficiente de correlação (algoritmo Ferreira <i>et al.</i> , (2005), algoritmo EWP–PCA e primeira proposta de algoritmo).....	104
Tabela 5.3 - Comparação entre os algoritmos baseado nos eventos de erro (algoritmo Ferreira <i>et al.</i> , (2005), algoritmo EWP–PCA e primeira proposta de algoritmo).....	105
Tabela 5.4 - Comparação entre os algoritmos baseados na máxima amplitude dos eventos de erro (algoritmo Ferreira <i>et al.</i> , (2005), algoritmo EWP–PCA e primeira proposta de algoritmo).....	105
Tabela 5.5 - Comparação entre os algoritmos baseados na duração dos eventos de erro (algoritmo Ferreira <i>et al.</i> , (2005), algoritmo EWP–PCA e primeira proposta de algoritmo).....	105
Tabela 5.6 - Significância estatística obtida na comparação dos algoritmos miolétricos..	106
Tabela 5.7 - Comparação baseada no percentual erro–sinal entre: (A) primeira variante, (B) segunda variante, (C) terceira variante, (D) algoritmo Ferreira <i>et al.</i> (2005), (E) primeira proposta de algoritmo e (F) método EWP–PCA.....	109
Tabela 5.8 - Comparação baseada no coeficiente de correlação.....	109
Tabela 5.9 - Comparação baseada no número de eventos de erro.....	110
Tabela 5.10 - Comparação baseada na amplitude máxima dos eventos de erro.....	110
Tabela 5.11 - Comparação baseada na duração máxima dos eventos de erro.....	111
Tabela 5.12 - Significância estatística obtida na comparação entre a primeira variante de algoritmo baseada em fusão de dados com o algoritmo Ferreira <i>et al.</i> (2005), a primeira proposta de algoritmo e o método EWP–PCA.....	112

Tabela 5.13 - Significância estatística obtida na comparação da segunda variante de algoritmo baseada em fusão de dados com o algoritmo Ferreira <i>et al.</i> (2005), a primeira proposta de algoritmo e o método EWP-PCA.....	112
Tabela 5.14 - Significância estatística obtida na comparação da terceira variante de algoritmo baseada em fusão de dados com o algoritmo Ferreira <i>et al.</i> (2005), a primeira proposta de algoritmo e o método EWP-PCA.....	112
Tabela 5.15 - Resultados das métricas estatísticas obtidas durante a implementação de teste com interferência da rede elétrica: (1) percentual erro-sinal, (2) coeficiente de correlação, (3) número de eventos de erro, (4) amplitude máxima e (5) duração máxima; em uma comparação entre: (A) primeira variante, (B) segunda variante, (C) terceira variante, (D) algoritmo Ferreira <i>et al.</i> (2005), (E) primeira proposta de algoritmo e (F) método EWP-PCA.....	120

## LISTA DE FIGURAS

Figura 1.1 - Estrutura mecânica da prótese de perna em desenvolvimento, adaptado de (Ferreira <i>et al.</i> , 2005). .....	1
Figura 2.1 - Neurônios (a) Motor e (b) Sensorial. Adaptado de (Beltramini, 1999).....	11
Figura 2.2 - Representação esquemática da geração do sinal mioelétrico a partir da somatória dos MUAPTs de $n$ unidades motoras de um músculo. Adaptado de (Basmajian e DeLuca, 1985).....	14
Figura 2.3 - Sinal mioelétrico captado no músculo Vasto Lateral por eletrodos de superfície, adquirido do bloco de instrumentação da prótese de perna.....	14
Figura 2.4 - Configuração bipolar utilizada na medição dos sinais mioelétricos, adaptado de (DeLuca, 2006).....	15
Figura 2.5 - Diagrama de blocos que apresenta a relação entre um sistema normal (indivíduo sem amputação) e mioelétrico (prótese ativa). Adaptado de (Oskoei e Hu, 2007).....	20
Figura 2.6 - Sistema do controle mioelétrico baseado em reconhecimento de padrões.....	21
Figura 2.7 - Erro de classificação de padrões mioelétricos comparando o comprimento do segmento em estado transitório e permanente. Adaptado de (Oskoei e Hu, 2007).....	22
Figura 2.8 - Estimativa da função de densidade de probabilidade normalizada do SME. Adaptado de (Clancy <i>et al.</i> , 1995).....	29
Figura 2.9 - Variação da qualidade do espaço característico com o tamanho da janela de dados. Abreviações: integral do sinal mioelétrico (IAV), número de cruzamentos por zero (ZC), variância amostral (VAR), primeiro coeficiente auto-regressivo (AR1), operador $v$ -order (V), operador $\log$ (LOG), amplitude <i>willison</i> (WAMP) e histograma de EMG (HIST). Adaptado de (Zardoshti-Kermani <i>et al.</i> , 1995).....	39
Figura 2.10 - Variação da qualidade do espaço característico com amplitudes de ruído branco. Adaptado de (Zardoshti-Kermani <i>et al.</i> , 1995).....	40
Figura 3.1 - (a) Protótipo de prótese; (b) sistema de instrumentação com sensores proprioceptivos; (c) diagrama esquemático do sistema de instrumentação.....	52

Figura 3.2 - Localização dos eletrodos: (a) músculo agonista; (b) músculo antagonista; (c) sensores eletrogoniômetro e giroscópios.....	54
Figura 3.3 - SMES adquirido em músculos agonista e antagonista: canal de eletromiografia #1 (músculo do reto femoral); canal de eletromiografia #2 (músculo semitendinoso); canal de eletrogoniometria (coleta do deslocamento angular no joelho); sensores giroscópios (coleta da velocidade angular) no músculo e na perna.....	55
Figura 3.4 - Filtragem adaptativa implementada em um SMES coletado no músculo reto femoral, contaminado com ruído de 60 Hz. Sinal adquirido no sistema de bioinstrumentação.....	57
Figura 3.5 - Estimação do ângulo realizada pelo algoritmo de extração e classificação de padrões: (a) sem filtragem adaptativa do SMES, (b) com filtragem adaptativa do SMES.....	58
Figura 3.6 - Interface visual do software de tempo real.....	60
Figura 3.7 - Colocação do equipamento de bioinstrumentação no indivíduo para a implementação do protocolo experimental.....	62
Figura 3.8 - Zonas de estudo utilizadas durante o protocolo experimental #1.....	63
Figura 3.9 - Exemplo de registros dos SMEs e ângulo em cada um dos quatros voluntários; A, B, C e D.....	66
Figura 4.1 - Diagrama geral de blocos do algoritmo mioelétrico.....	71
Figura 4.2 - Esquema do filtro adaptativo RLS.....	72
Figura 4.3 - Combinação do histograma de EMG e o modelo auto-regressivo.....	74
Figura 4.4 - Esquema do mapa auto-organizável.....	76
Figura 4.5 - Esquema da rede perceptron multicamada para o algoritmo mioelétrico.....	79
Figura 4.6 - Estrutura do algoritmo mioelétrico.....	81
Figura 4.7 - Esquema geral de funcionamento do processo de coleta do SMES e estimação do ângulo do joelho.....	81
Figura 4.8 - Esquema do processo de extração de características e classificação para as variantes de algoritmos baseadas em fusão de dados.....	86
Figura 4.9 - Esquema de funcionamento da primeira variante de algoritmo mioelétrico....	87
Figura 4.10 - Esquema de funcionamento da segunda variante de algoritmo mioelétrico..	89
Figura 4.11 - Esquema de funcionamento da terceira variante de algoritmo mioelétrico..	90

Figura 5.1 - Ângulos medidos e a estimativa dos processos de treinamento e validação para o sujeito #2: (a) treino; (b) validação; (c) validação filtrada.....	97
Figura 5.2 - Ângulos medidos e a estimativa do processo de validação para o sujeito #2: (a) primeira proposta; (b) segunda proposta; (c) terceira proposta.....	98
Figura 5.3 - Comparação do erro médio quadrático e número de padrões de entrada durante o treinamento da rede perceptron multicamada.....	99
Figura 5.4 - Algoritmos mioelétricos utilizados para as comparações com as propostas desenvolvidas: (a) Ferreira <i>et al.</i> (2005); (b) Wang <i>et al.</i> (2006).....	101
Figura 5.5 - Resultados da validação na estimação do ângulo para medição representativa de um indivíduo, em uma comparação entre: (a) algoritmo de Ferreira <i>et al.</i> (2005), (b) primeira proposta de algoritmo, (c) método EWP-PCA, (d, e, f) primeira, segunda e terceira propostas de algoritmos baseadas em fusão de dados. A linha sólida (em vermelho) representa o nível limiar que foi utilizado para calcular as estatísticas dos eventos de erro (10 graus).....	115
Figura 5.6 - Resultados da validação na estimação do ângulo para uma coleta de dados com presença de artefatos em um indivíduo, em uma comparação entre: (a) algoritmo de Ferreira <i>et al.</i> (2005), (b) primeira proposta de algoritmo, (c) método EWP-PCA, (d, e, f) primeira, segunda e terceira propostas de algoritmos baseadas em fusão de dados. A linha sólida (em vermelho) representa o nível limiar que foi utilizado para calcular as estatísticas dos eventos de erro (10 graus).....	116
Figura 5.7 - Resultados da validação na estimação do ângulo para uma coleta de dados com presença de interferência da rede elétrica em um indivíduo, em uma comparação entre: (a) algoritmo de Ferreira <i>et al.</i> (2005), (b) primeira proposta de algoritmo, (c) método EWP-PCA, (d, e, f) primeira, segunda e terceira propostas de algoritmos baseadas em fusão de dados. A linha sólida (em vermelho) representa o nível limiar que foi utilizado para calcular as estatísticas dos eventos de erro (10 graus).....	119
Figura A - Zonas de estudo utilizadas durante a implementação do segundo protocolo experimental nos músculos agonistas e antagonistas.....	140
Figura B - Sinais obtidos durante o protocolo experimental nos doze voluntários.....	142
Figura D - Visualização do conjunto dos sinais mioelétricos e proprioceptivos desde o <i>Matlab</i> .....	148



Figura E - Diagramas esquemáticos do sistema de bioinstrumentação.....149

## LISTA DE SÍMBOLOS, NOMENCLATURA E ABREVIACÕES

<i>AR</i>	-Autoregressive
<i>ARC</i>	- Autoregressive-derived cepstrum
<i>ARM</i>	-Architecture RISC Machine
<i>ARMA</i>	-Autoregressive – Moving Average
<i>Ag-AgCl</i>	-Cloreto de prata
<i>ANN</i>	-Artificial Network Nets
<i>A/D</i>	-Analog-Digital
<i>CC</i>	-Corrente Continua
<i>CEP</i>	-Cepstral Coefficients
<i>CKLM</i>	-Cascade Kernel Learning Machine
<i>CSFNN</i>	-Conic Section Function Neural Network
<i>CMRR</i>	- Comum Mode Rejection Ratio
<i>DB</i>	-Davies-Bouldin
<i>DFC</i>	- Fourier-derived ceptrum
<i>DKF</i>	-Decentralized Kalman Filter
<i>EDM</i>	-Euclidean Distance Measure
<i>EMG</i>	-Eletromyographic
<i>EWP</i>	-Energy wavelet packets
<i>FCM</i>	-Fuzzy C-Means
<i>FCNN</i>	-Fuzzy Clustering Neural Network
<i>FIR</i>	-Finite Impulse Response
<i>FT</i>	-Fourier Transform
<i>GA</i>	-Genetic Algorithm
<i>GMM</i>	-Gaussian Mixture Model
<i>GMP</i>	-Gabor Matching Pursuit
<i>IEMG</i>	-Integrated Eletromyographic
<i>IIR</i>	-Infinite Impulse Response

<i>iMBF</i>	- <i>Input membership function</i>
<i>IRB</i>	- <i>Inference Rule</i>
<i>KNN</i>	- <i>K-Nearest Neighborhood</i>
<i>LDA</i>	- <i>Linear Discriminant Analysis</i>
<i>LDI</i>	- <i>Fishers Linear Discriminant Index</i>
<i>LM</i>	- <i>Levenberg-Marquardt</i>
<i>LMS</i>	- <i>Least Mean Square</i>
<i>LP</i>	- <i>Linear Perceptron</i>
<i>LS</i>	- <i>Least Square</i>
<i>MA</i>	- <i>Moving Average</i>
<i>MAV</i>	- <i>Mean Absolute Value</i>
<i>MLP</i>	- <i>Multi-Layer Perceptron</i>
<i>MLM</i>	- <i>Maximum Likelihood Method</i>
<i>MMC</i>	- <i>Multimedia Memory Card</i>
<i>MSE</i>	- <i>Mean Squared Error</i>
<i>MUAP</i>	- <i>Motor Unit Action Potential</i>
<i>MUAPT</i>	- <i>Motor Unit Action Potential Train</i>
<i>oMBF</i>	- <i>Output membership function</i>
<i>PCA</i>	- <i>Principal Components Analysis</i>
<i>RBF</i>	- <i>Radial Basic Function</i>
<i>RLS</i>	- <i>Recursive Least Square</i>
<i>RMS</i>	- <i>Root Mean Square</i>
<i>SEMG</i>	- <i>Surface Eletromyographic</i>
<i>SRM</i>	- <i>Structural Risk Minimization</i>
<i>SME</i>	- <i>Sinal Mioelétrico</i>
<i>SMES</i>	- <i>Sinal Mioelétrico de Superfície</i>
<i>SNR</i>	- <i>Signal - Noise Rate</i>
<i>SNC</i>	- <i>Sistema Nervoso Central</i>
<i>STFT</i>	- <i>Short-Time Fourier Transform</i>

<i>SOM</i>	<i>-Self Organizing Maps</i>
<i>SVM</i>	<i>- Support Vector Machine</i>
<i>TD</i>	<i>-Time Domain</i>
<i>TDANN</i>	<i>-Time-Delayed Artificial Neural Network</i>
<i>TDS</i>	<i>- Time domain statistics</i>
<i>VAR</i>	<i>-Variance</i>
<i>VWA</i>	<i>- Variance Weighted Average</i>
<i>WAMP</i>	<i>-Willison Amplitude</i>
<i>WDM</i>	<i>-Weighted Distance Measure</i>
<i>WL</i>	<i>-Waveform Length</i>
<i>WT</i>	<i>-Wavelet Transform</i>
<i>WPT</i>	<i>-Wavelet Packets Transform</i>
<i>ZC</i>	<i>-Zero Crossings</i>

# 1- INTRODUÇÃO

O trabalho de tese que se apresenta é parte do projeto de desenvolvimento em um primeiro estágio de uma prótese ativa de perna para amputados acima do joelho. Conforme ilustrado na Figura 1.1, a prótese apresenta três graus de liberdade: um para o joelho (plano sagital) e dois movimentos para o pé (plano sagital e plano frontal).




Figura 1.1 - Estrutura mecânica da prótese de perna em desenvolvimento, adaptado de (Ferreira *et al.*, 2005).

Os três graus de liberdade são referentes aos ângulos  $\theta_1$ ,  $\theta_2$  e  $\theta_3$ , cuja atuação é feita por motores redutores de corrente contínua e um circuito de acionamento. O protótipo mecânico proposto será fixado ao membro amputado do paciente por meio de um casulo de fixação, modelo já utilizado em próteses comerciais. Os sensores dos sinais mioelétricos (SME) estarão posicionados na perna sadia do paciente. Os comandos de acionamento serão gerados por meio dos sinais mioelétricos de superfície (SMES) provenientes da coxa do paciente que serão processados através dos algoritmos de extração de características e classificação de padrões mioelétricos. Dadas as características da prótese, que possui eixos de tornozelo e de pé, é necessário utilizar outras fontes de informação, além do SME, os quais serão provenientes de diferentes sensores que estarão integrados a um modelo preditivo de movimento. Este modelo será usado para determinar referências de posicionamento do pé com relação ao solo (altitude) (Ferreira *et al.*, 2005).

As atividades atuais estão relacionadas à idealização de uma arquitetura modular de instrumentação e de controle, procurando o uso de técnicas comumente empregadas em robótica bípede, uma vez que os SMEs relacionam-se apenas ao  $\theta_1$  do joelho.  $\theta_2$  e  $\theta_3$  serão determinados por meio de modelos preditivos de intenção de movimento, alimentados por mediação dos diversos sensores da prótese. Portanto, na parte de instrumentação, estão presentes sensores ultrasônicos para estimação do ângulo de inclinação do pé em relação ao solo, e um acelerômetro para medição de posição e estimação das velocidades dos eixos das juntas da perna.

### **1.1–SINAIS MIOELÉTRICOS NA DETECÇÃO DE INTENÇÃO DE MOVIMENTO**

Com o avanço da tecnologia de equipamentos médicos, tornou-se possível a implementação e o processamento de sinais biomédicos (eletrocardiografia, eletroencefalografia, eletromiografia etc.), e com isso, aperfeiçoou-se a qualidade do diagnóstico clínico de pacientes sujeitos às diferentes patologias existentes. De maneira similar, utilizando tais avanços, foram desenvolvidos dispositivos para melhorar a qualidade de vida de pessoas com amputações, por meio do desenvolvimento de próteses controladas por sinais mioelétricos de superfície (Castellini e Smagt, 2009; Kastner *et al.*, 1999). A primeira tentativa de produzir sistemas robóticos para pessoas com deficiências físicas teve início no final dos anos 60 e início dos anos 70 (Merletti e Parker, 2004). Praticamente todos os esforços iniciais falharam em atingir o estágio de produção, devido à rejeição dos prováveis usuários aos projetos desenvolvidos, principalmente nas áreas de interface homem-máquina. Com o sucesso da robótica na área industrial, novos conhecimentos puderam ser aplicados no auxílio à integração de pessoas com deficiências físicas à vida social e ao trabalho. Por meio do avanço da tecnologia, diferentes técnicas foram aperfeiçoadas, visando maior interação entre os diferentes dispositivos mecânicos, elétricos e sensoriais com o usuário de próteses, além do desenvolvimento de novos algoritmos que permitem que mais informação seja recebida do usuário.

Segundo o censo do Instituto Brasileiro de Geografia e Estatística, existem mais de 6,5 milhões de brasileiros que possuem deficiência física ou motora, como amputações,

lesões medulares, entre outras. No Brasil, as principais causas das amputações de membros inferiores são os acidentes automobilísticos, os acidentes de trabalho, os problemas vasculares e as tumorações malignas (Censo do Instituto Brasileiro de Geografia e Estatística, 2000). Isto motiva o desenvolvimento em campos de pesquisas orientadas a estudos de reabilitação que têm como principal objetivo restaurar as funções motoras perdidas e auxiliar o tratamento das deficiências motoras, em especial no desenvolvimento de próteses ativas que permitam o controle através da informação extraída dos SMEs.

No estudo da implementação dos movimentos para as próteses controladas, os principais problemas são ocasionados pela forma de transmitir às próteses a intenção dos movimentos do usuário. O sinal mioelétrico (SME) vem sendo usado de forma efetiva em sistemas de controle de próteses. Essa forma de controle, chamada controle mioelétrico, encontrou uso difundido em indivíduos com amputações ou com membros superiores congenitamente deficientes (Merletti e Parker, 2004; Parker *et al.*, 2006).

O sinal mioelétrico de superfície (SMES) possui muitas informações que possibilitam determinar a intenção de movimento do usuário, obtidas via contração muscular, detectada através do uso de eletrodos de superfície (Englehart *et al.*, 1995; Merletti e Parker, 2004; Oskoei e Hu, 2007). Os padrões gerados a partir da contração muscular podem ser utilizados no sistema de controle mioelétrico. A principal vantagem do controle mioelétrico sobre outros tipos de sistema de controle, tais como os sistemas mecânicos controlados pelo corpo, é que, mesmo sem controle da mão, obedece à intenção de movimento do usuário. Os sistemas mioelétricos de superfície são não-invasivos e os sinais detectados a partir da superfície da pele podem ser utilizados para aplicar uma força proporcional no acionamento da prótese (Oskoei e Hu, 2007). As indicações para o controle mioelétrico incluem a localização apropriada dos eletrodos na zona de amputação, de forma a garantir um controle apropriado do movimento via captação adequada dos sinais dos músculos.

O desenvolvimento de tecnologias orientadas ao controle mioelétrico ainda encontram limitações que, sendo solucionadas, podem melhorar o controle mioelétrico multifuncional. As mesmas são focadas no incremento do posicionamento de sensores

para a coleta dos SMEs em a aplicação de retroalimentação sensorial. Um exemplo é o desenvolvimento de eletrodos *wireless*, contido em uma matriz que podem fornecer mais sinais de entrada para o processo de classificação, com o objetivo de melhorar a exatidão. A utilização de retroalimentação sensorial com os SMEs pode fornecer padrões de entrada complementares no estágio de classificação para uma discriminação mais precisa e intuitiva. A maior parte dos sistemas desenvolvidos utilizam os SMEs a partir do membro residual do amputado como comando de controle para uma prótese externa. No entanto, os sistemas só fornecem níveis discretos ou binários para o movimento, enquanto que as atividades diárias requerem um movimento de controle contínuo do membro.

## **1.2– PROBLEMA DA PESQUISA**

Amputados acima do joelho que possuem próteses mecânicas passivas encontram grandes dificuldades de locomoção em terrenos inclinados e com obstáculo, como rampas e escadas. Pelo fato de tais próteses serem passivas, elas não apresentam, em sua maior otrito que facilite a locomoção nesses terrenos, vantagem que poderia ser obtidas na estimação contínua dos ângulos de uma prótese ativa. Estudos preliminares em prótese de pernas ativas mostram os benefícios de uma maior independência, comparada com próteses passivas de joelhos, alcançada pelas pessoas com deficiências no uso de próteses ativas (Kastner et al., 1999; Dietl e Bargehr, 1997).

Mesmo com o avanço das capacidades e potencialidades do controle mioelétrico, é necessária a utilização de interfaces complementares que possibilitem atuar em todos os requisitos para garantir um controle mais preciso. O nível de atividade muscular em contrações estáticas ou dinâmicas é o fator mais importante no reconhecimento do controle mioelétrico. A aplicação de métodos no domínio temporal e espectral pode aumentar o desempenho dos algoritmos mioelétricos, além de ser eficiente computacionalmente no processo de extração de características dos sinais mioelétricos (Hargrove *et al.*, 2008).

Com o recente desenvolvimento das próteses multifuncionais, é importante aumentar a exatidão na extração e na classificação dos padrões. Justo exige a amplificação dos canais a serem processados e o uso de sistemas multisensoriais. A fusão de



informações provenientes de sinais mioelétricos e de sensores de movimento de membros (sensores proprioceptivos) permitem obter confiabilidade nos sistemas de controle de malha fechada e pode ser usada para a implementação de correções na estimação que se obtém a partir dos algoritmos mioelétricos (López *et al.*, 2009; Delis *et al.*, 2009).

Outro ponto de destaque é o tempo de resposta do sistema que deve estar presente no desenvolvimento do algoritmo mioelétrico (Oskoei e Hu, 2007). O mesmo não pode gerar atrasos perceptíveis ao usuário durante a operação. Há um compromisso entre o tempo de resposta e a exatidão. Assim, a implementação dos algoritmos em seus diferentes estágios (até obterem-se os padrões e gerarem-se os comandos de ação) deve garantir um tempo de resposta menor ou igual a 300 ms (Englehart e Hudgings, 2003; Oskoei e Hu, 2007).

No que se refere ao controle mioelétrico, este deve ter a capacidade de apresentar, da forma mais natural possível, o movimento dos músculos de acordo com o seu processo de aprendizagem. Estes precisam de uma adequada robustez contra as condições de variação durante a operação (Oskoei e Hu, 2007). Na execução do algoritmo mioelétrico, é de grande importância garantir uma adequada aceitação por parte do usuário. O desenvolvimento de classificadores de padrões multifuncionais e os algoritmos mioelétricos devem possibilitar ao usuário gerar padrões através de movimentos normais (Zecca *et al.*, 2002; Englehart e Hudgings, 2003).

A utilização de sistemas multisensoriais mioelétricos tem o objetivo de melhorar a exatidão nos processos de extração e classificação de padrões. No entanto, a quantidade de informação redundante no espaço característico dos vetores de entrada na rede (com a função da classificação dos padrões mioelétricos) aumenta. Isso também provoca aumento substancial de tempo de aprendizagem da rede, sendo necessário inserir um estágio de projeção de características, com vistas a reduzir a dimensionalidade do vetor de entrada (Yi-Hung *et al.*, 2007).

O equipamento de instrumentação ligado à prótese de perna deve permitir a aquisição e o condicionamento dos sinais mioelétricos e, com isso, garantir um

desempenho satisfatório, em qualquer ambiente. Para isso, o sistema proposto deve ser imune aos mais diversos tipos de ruídos e interferências. Faz-se necessária a utilização de filtros que devem ser desenhados com os parâmetros requeridos, principalmente para não alterar as características nos domínios tempo e frequência do sinal captado (Zecca *et al.*, 2002; SENIAM, 2008).

### **1.3– OBJETIVOS DO TRABALHO**

Os objetivos deste trabalho são:

1. Projeto, construção e caracterização de um sistema de instrumentação biomédico para a aquisição e o pré-processamento de sinais mioelétricos. Além do SMES, o sistema permite a utilização de outras fontes de informação, como giroscópios para medição dos componentes da velocidade angular, e um goniômetro para medição de posição dos eixos das juntas da perna.
2. Desenvolvimento de um algoritmo que permita extrair a informação sobre a intenção de movimento utilizando sinais mioelétricos para a estimação do ângulo do joelho, de forma contínua.
3. Desenvolvimento de um algoritmo que permita extrair a informação sobre a intenção de movimento utilizando dados dos sinais mioelétricos e informação de sensores proprioceptivos, para a estimação do ângulo do joelho, de forma contínua, que possibilitem melhorar a confiabilidade e robustez no processo de classificação dos padrões.
4. Validar as propostas dos algoritmos, com análises de robustez, confiabilidade e exatidão por meio de indicadores quantitativos.

## **1.4– HIPÓTESES DO TRABALHO**

A partir das análises dos objetivos e da informação fornecida pelos sinais mioelétricos de superfície como campo de ação da pesquisa, foi formulado como hipótese para o trabalho desta tese de doutorado a possibilidade da implementação de algoritmos mioelétricos para detectar a intenção de movimento, que possibilitem estimar eficientemente o ângulo de deslocamento do joelho e a conseqüente intenção de movimento. Em uma primeira proposta, realiza-se o processo de classificação de padrões mioelétricos, utilizando a informação do SMES, os quais que constituem os parâmetros de entrada de um bloco algorítmico de extração, redução de dimensionalidade e classificação de padrões. A segunda proposta permitirá a fusão de dados do SMES e à obtenção de informação de velocidade angular (sensores girômetros), utilizando estágios de extração, classificação de padrões e correção da estimativa do ângulo, através do filtro de *Kalman*.

## **1.5– JUSTIFICATIVA DO TRABALHO**

O aspecto inovador da solução proposta está na possibilidade de se ter uma prótese que utiliza não somente sinais de EMG, mas também modelos preditivos da robótica bípede para a ativação dos eixos do pé. Sinais SME de superfície extraídos na coxa permitem determinar a intenção de movimento apenas da junta do joelho. O projeto deverá auxiliar na reabilitação de amputados acima do joelho, permitindo a locomoção em terrenos inclinados e escadas. Existe a necessidade de desenvolver algoritmos que além da informação extraída de intenção de movimento com sinais eletromiográficas, as mesmas possam fusionar-se com outras variáveis, especialmente as relacionadas com a propriocepção. Estas variáveis oferecem ao usuário um tipo de retroalimentação que permite controlar a intensidade do músculo com alta precisão. Exemplos dessas variáveis são o ângulo das articulações do joelho e a força exercida pelo músculo.

Como resultado das pesquisas realizadas, foram publicadas 1 artigo em periódico qualis A1 internacional e 1 capítulo de livro; a seguir:

Delis, A. L., Carvalho, J. L., da Rocha, A. F., Ferreira, R. U., Rodrigues, S. S., Borges, G. A. Estimation of the knee joint angle from surface electromyographic signals for active control of leg prostheses. In: *Physiological Measurement*, 2009, (30), 931-946.

Delis, A. L., Carvalho, J. L. A., da Rocha, A. F., Nascimento, F. A., Borges, G. A. Knee Angle Estimation Algorithm for Myoelectric Control. In: *Communications in Computer and Information Science*. ed. Berlin/Heidelberg : Springer-Verlag, 2010, v.52, p. 124-135.

Também foram publicadas 6 artigos em anais de congresso nacionais e internacionais:

Delis, A. L., da Rocha, A. F., Santos, I., Sene Jr, I. G., Salomoni, S., Borges, G. A. Development of a Microcontrolled Bioinstrumentation System for Active Control of Leg Prostheses. In: *Proceedings of the 30<sup>th</sup> Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2008, p.2392 – 2396.

Delis, A. L., Nascimento, F. A. O., Carvalho, J. L. A., da Rocha, A. F., Borges, G. A. Algoritmo de estimação do ângulo do joelho para controle mioelétrico. In: *Anais do XXI Congresso Brasileiro de Engenharia Biomédica*, 2008, p.1 – 4.

Delis, A. L., da Rocha, A. F., Carvalho, J. L. A., Nascimento, F. A. O., Rodrigues, S. S., Borges, G. A. Sistema para Estimação de Intenção de Movimento em Prótese de Perna. In: *Anais do XXI Congresso Brasileiro de Engenharia Biomédica*, 2008, p.1 – 4.

Delis, A. L., Carvalho, J. L. A., da Rocha, A. F., Nascimento, F. A., Borges, G. A. Development of a myoelectric controller based on knee angle estimation. In: *Proceedings of the Second International Conference on Biomedical Electronics and Devices*, 2009, p.97 – 103. *Best Paper Award Certificate BIOSTEC 2009*.

Delis, A. L., Carvalho, J. L. A., Borges, G. A., Rodrigues, S. S., Santos, I., da Rocha, A. F. Fusion of electromyographic signals with proprioceptive sensor data in myoelectric pattern recognition for control of active transfemoral leg prostheses In: *Proceedings of the 31<sup>st</sup>*

Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2009, p.4755 – 4758.

Delis, A. L., Carvalho, J. L. A., Seisdedos C. V., Borges, G. A., da Rocha, A. F. Myoelectric control algorithms for leg prostheses based on data fusion with proprioceptive sensors. In: Proceedings ISSNIP Biosignals and Biorobotics Conference, 2010, p.137 – 142.

## **1.6– ESTRUTURA DO DOCUMENTO**

No capítulo dois, apresenta-se uma revisão bibliográfica sobre os métodos empregados na extração e classificação de padrões mioelétricos, além de uma análise do estado da arte da tecnologia nesse campo. O capítulo três mostra as características da plataforma experimental composta pelo sistema de bioinstrumentação e o software para a coleta de dados. São também apresentados, os dois protocolos experimentais efetuados em indivíduos saudáveis, para avaliar as propostas dos algoritmos mioelétricos. As propostas dos algoritmos mioelétricos desenvolvidos para a implementação dos estágios de extração – classificação dos padrões e fusão de dados dos sensores proprioceptivos com os sinais mioelétricos são apresentadas no capítulo quatro. No capítulo quinto, apresentam-se os resultados e a discussão, baseados no desempenho dos algoritmos propostos e sua comparação com outras variantes de algoritmos. O capítulo sexto apresenta as conclusões finais desta tese de doutorado.

## **2– REVISÃO BIBLIOGRÁFICA**

Inúmeras técnicas já foram desenvolvidas para o uso dos sinais mioelétricos para o controle de prótese. O objetivo dessas técnicas é conseguir extrair informação desses sinais de tal forma que se consiga uma aplicação eficiente. Várias questões podem ser consideradas quando se trata do controle de prótese (seja de perna, braço ou outra parte do corpo humano) a partir dos SMEs. Dentre elas, pode-se mencionar a instrumentação de aquisição do sinal, que pode ser monopolar (um canal), bipolar (dois canais) ou até mesmo aquisição por múltiplos canais, o que, a princípio provê uma gama maior de informação, mas que, por outro lado, pode apresentar maior quantidade de informação redundante e necessitar de um processamento mais sofisticado. A seguir, apresenta-se uma revisão bibliográfica, abordando os aspectos relacionados ao controle mioelétrico de prótese.

### **2.1– O PROCESSO DE CONTRAÇÃO MUSCULAR**

Para que ocorra uma contração muscular, é necessária a ocorrência de vários fatores, como o potencial de ação conduzido pelo neurônio motor, a transmissão sináptica, os potenciais de ação muscular (cuja soma representa o sinal mioelétrico) e a contração das fibras musculares (Beltramini, 1999). A célula nervosa ou neurônio, como outras células biológicas, é delimitada por uma membrana celular semipermeável, responsável pela capacidade desta célula de transmitir informações. No neurônio, podem-se identificar três estruturas: o corpo celular, os dendritos e o axônio (Figura 2.1). O corpo celular é a porção que contém citoplasma, núcleo e organelas. Em um neurônio motor, que comanda diretamente a contração das fibras musculares, a soma está entre os dendritos e o axônio, já em certos neurônios sensoriais localiza-se discretamente à margem do axônio. A função do axônio é a transmissão da informação na forma de pulsos regenerativos. Quando suas estruturas minúsculas recebem um potencial de ação, as mesmas liberam neurotransmissores, que são substâncias químicas utilizadas na transmissão do potencial de ação de um neurônio ao outro (Guyton, 1988).

As reações eletroquímicas responsáveis pela condução dos sinais nervosos nos neurônios são chamadas potenciais de ação neural (Guyton, 1988). Os potenciais de ação

neural são variações muito rápidas da diferença de potencial entre os meios externo e interno da membrana da célula nervosa. O potencial começa por uma variação abrupta de um potencial de repouso negativo para um potencial positivo e, rapidamente, retorna para um potencial negativo (Guyton, 1988). As placas motoras são as conexões entre as terminações nervosas e as fibras musculares. Através das mesmas, o potencial de ação é transmitido à fibra muscular, provocando a contração desta num processo químico de alta velocidade, e levam somente cerca de 1 milissegundo. O potencial de ação despolariza a membrana da fibra muscular e também penetra profundamente no interior desta. São estes potenciais de ação que produzem a contração da fibra muscular através da liberação de íons de cálcio para o interior das miofibrilas, provocando a interação dos filamentos de actina e miosina (Guyton, 1988).




Figura 2.1 – Neurônios (a) Motor e (b) Sensorial. Adaptado de (Beltramini, 1999).

## 2.2– O SINAL MIOELÉTRICO

O músculo esquelético é composto por vários fascículos musculares, e estes são formados por células chamadas de fibras musculares, que é uma célula cilíndrica com diâmetros variando entre 10 e 80  $\mu\text{m}$  (Beltramini, 1999). Cada fibra é constituída por centenas de miofibrilas, núcleos celulares e pelo Retículo Sarcoplasmático, envoltos em uma membrana plasmática, chamada de Sarcolema (Beltramini, 1999). O músculo consiste em eixos paralelos de fibras musculares. A ativação de cada fibra muscular é feita pelo axônio motor que inerva a fibra nervosa. De acordo com a posição e a função do músculo, o número de fibras musculares inervadas pelo mesmo axônio pode variar entre um ou mais de mil. O grupo formado pela célula nervosa motora da espinha dorsal, o axônio, e as fibras musculares que esta inerva constituem a unidade básica funcional do sistema muscular, sendo conhecido através da Unidade Motora. Quando um neurônio motor envia um potencial de ação, todas as fibras musculares da sua unidade motora são estimuladas, no entanto, no processo de estimulação acontecem pequenos atrasos entre as contrações. O resultado da soma algébrica dos potenciais de ação nas  $n$  fibras de uma unidade motora é chamado de Potencial de Ação da Unidade Motora, cuja sigla em inglês é MUAP (*Motor Unit Action Potential*) (DeLuca, 2006). Entre os fatores que influenciam as características dos MUAPs registrados, encontram-se (Konrad, 2005; DeLuca, 2006):

- Relação geométrica entre a superfície de detecção do eletrodo e a fibra muscular da unidade motora;
- Posição relativa entre a superfície de detecção do eletrodo e a zona de inervação (junção neuromuscular);
- Tamanho da fibra muscular (a amplitude do MUAP é proporcional ao diâmetro da fibra);
- Número de fibras musculares da unidade motora na região de detecção do eletrodo;
- Interface eletrodo/eletrolito: a junção eletro-química entre a superfície metálica de detecção e o tecido funciona como um filtro passa-altas. Função de filtragem dos tecidos: a amplitude do sinal mioelétrico é atenuada em 25% a cada 100 mm de distância entre o músculo e o eletrodo. Essa distância funciona como um filtro passa-baixas, reduzindo a banda de passagem e o ganho do sinal (DeLuca, 2006).



A duração de um MUAP é de aproximadamente de 2 a 10 ms, quando é captado com eletrodos de agulha apresenta amplitudes na faixa de 100  $\mu$ V a 2 mV e banda de frequência de 5 Hz a 10 kHz. Pelo fato do MUAP ter uma duração relativamente curta, as unidades motoras devem ser ativadas repetidamente para que possa sustentar uma contração muscular por períodos maiores. A sequência de MUAPs é denominada trem de potenciais de ação da unidade motora, cuja sigla em inglês é MUAPT (*Motor Unit Action Potential Train*). O SME é a somatória de MUAPTs das unidades motoras captadas pelo eletrodo de detecção na zona de estudo, ver Figura 2.2 (Merletti e Parker, 2004; DeLuca, 2006). Devido às diferenças entre os MUAPs, às variações na taxa de disparo dos neurônios e ao fato de que uma contração pode incluir vários músculos, o sinal mioelétrico foi descrito como um processo estocástico (DeLuca, 1979; US Department of Health and Human Services, 1992; Cram e Kasman, 1998), cuja função de densidade de probabilidade se aproxima de uma função gaussiana de média zero.

### **2.3- CAPTAÇÃO ACONDICIONAMENTO DO SINAL MIOELÉTRICO**

Para o controle da prótese, obtém-se um resultado mais interessante quando se utilizam eletrodos de superfície. Apesar de captarem sinais de uma região muito ampla, e de certa maneira desnecessários e redundantes, eles são não-invasivos (diferente dos eletrodos de agulha e fio), o que facilita imensamente a manipulação, além de serem mais higiênicos e de aplicação indolor (Basmajian e DeLuca, 1985; Winter, 1990). A Figura 2.3 mostra um sinal mioelétrico captado por eletrodos de superfície localizados no músculo vasto lateral (relacionado com a extensão do joelho). Na mesma, são apresentados os níveis de contração musculares obtidos a partir do SMES em um processo de extensão da perna, durante um protocolo experimental.

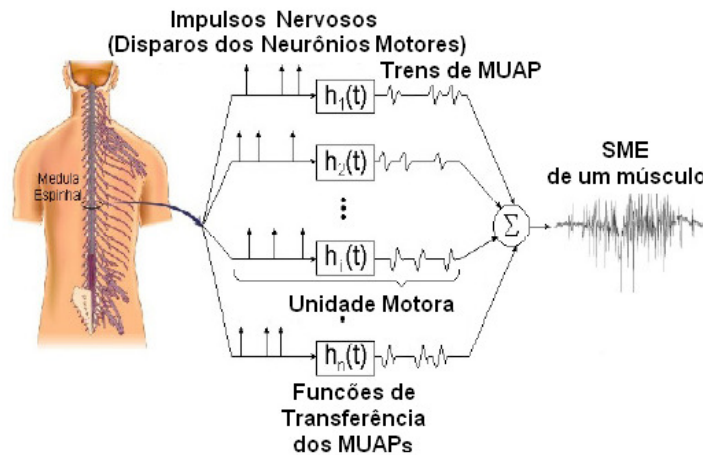


Figura 2.2 - Representação esquemática da geração do sinal mioelétrico a partir da somatória dos MUAPs de  $n$  unidades motoras de um músculo. Adaptado de (Basmajian e DeLuca, 1985).

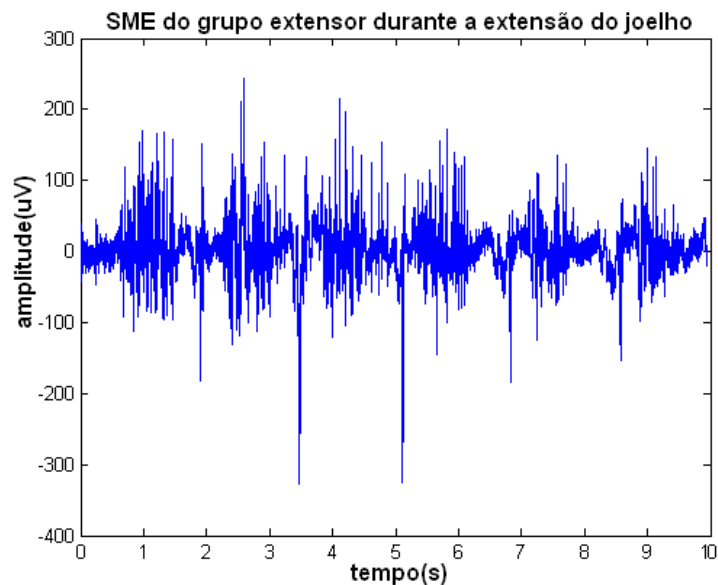


Figura 2.3 - Sinal mioelétrico captado no músculo Vasto Lateral por eletrodos de superfície, adquirido do bloco de instrumentação da prótese de perna.

O sinal mioelétrico obtido com eletrodos de superfície é influenciado pelas propriedades dos filtros das camadas epiteliais e da interface eletrodo-pele, e apresenta componentes frequenciais desde CC até cerca de 500 Hz, mostrando maior concentração do sinal dentro da faixa de 50 Hz - 150 Hz (Delsys, 1996). Suas amplitudes máximas variam entre 50  $\mu$ V e 5 mV, e seus valores alteram-se de acordo com o tipo de músculo analisado, do nível de contração muscular e da localização dos eletrodos (Enoka, 1994; Delsys, 1996). O SMES pode ser obtido por configurações monopolares e bipolares. A

configuração monopolar utiliza dois eletrodos, obtendo-se a diferença de potencial entre dois pontos, sendo um deles a referência. Na configuração bipolar são obtidos dois sinais em relação a uma referência, e é feita a diferença entre eles. Neste tipo de configuração, são utilizados três pontos de detecção. A configuração bipolar é a mais utilizada, devido a sua alta rejeição a sinais de modo comum (Figura 2.4). Para ambas as configurações, normalmente utilizam-se eletrodos confeccionados com prata revestida com cloreto de prata (Ag-AgCl), pois é um metal nobre não-polarizável, evitando assim a indução de um nível CC nos eletrodos de detecção. Geralmente, estes eletrodos são utilizados em conjunto com um gel ou pasta condutora que contém íons de cloro, com o objetivo de reduzir a impedância de contato entre o eletrodo e a pele (Basmajian e DeLuca, 1985).




Figura 2.4 - Configuração bipolar utilizada na medição dos sinais mioelétricos, adaptado de (DeLuca, 2006).

Para a implementação do estágio de aquisição e condicionamento dos sinais mioelétricos, normalmente se utiliza um pré-amplificador com ganho entre 10 e 50 dB. No ato de “casar” a impedância do eletrodo de registro com a impedância de entrada do próximo estágio de amplificação, é estabelecido um ganho entre 10 e 1000. Os cabos utilizados na entrada do amplificador devem ser blindados e ter baixa capacitância entre eles (DeLuca e Knaflitz, 1992). Os amplificadores utilizados são, em geral, amplificadores de instrumentação, assim se garante que o ruído induzido nas duas entradas do amplificador seja subtraído e, portanto, seja minimizada a interferência de modo comum. Como requisito para um alto desempenho do amplificador de instrumentação, a impedância de entrada e o CMRR (sigla em inglês “*Common Mode Rejection Ratio*”) devem ser altos (CMRR > 80 dB, impedância de entrada > 100 M $\Omega$ ) (Delsys, 1996; SENIAM, 2008). Para a localização dos eletrodos, tendo em conta o uso do amplificador

de instrumentação, é necessário que o eletrodo de referência tenha uma área de aproximadamente 4 cm<sup>2</sup> e este deve estar localizado preferencialmente em uma região sem músculos, de forma a não interferir na medida. Os eletrodos de captação podem ser compostos por 2 discos de Ag-AgCl com 2 mm de diâmetro, e, no caso de utilizar barras de Ag-AgCl a largura deve ser 1 mm e comprimento de 10 mm (Basmajian e DeLuca, 1985). De acordo com a configuração utilizada, a distância entre os mesmos é de 1 cm. A melhor localização do eletrodo é entre a junção neuromuscular e o tendão de inserção do músculo. O eixo longitudinal dos eletrodos (que passa através de ambas as superfícies de detecção) deve estar alinhado paralelo à longitude das fibras musculares (Basmajian e DeLuca, 1985).

## **2.4- INTERFERÊNCIA NO SINAL MIOELÉTRICO**

Além das considerações anteriores, o SME pode ser contaminado por ruído. Para incrementar a relação sinal/ruído, faz-se imprescindível o uso de filtros na faixa 20-500 Hz, utilizando filtros passa-banda (Zecca *et al.*, 2002; SENIAM, 2008).

As principais perturbações que podem interferir na aquisição do sinal mioelétrico são provenientes da indução eletromagnética da rede elétrica e dos artefatos de movimento. A interferência da rede elétrica provoca muitos prejuízos no sinal mioelétrico, principalmente porque está presente em quase todos os equipamentos de laboratório e, na vida cotidiana, sua amplitude é consideravelmente alta em relação às baixas amplitudes dos SMEs (Zhang *et al.*, 1997). A forma de onda da rede elétrica tem seus primeiros harmônicos (60 Hz, 120 Hz, 180 Hz e 240 Hz) dentro da faixa de maior concentração de energia do sinal mioelétrico (Basmajian e DeLuca, 1985). Existem várias técnicas que permitem atenuar a interferência de 60 Hz, que vão desde a utilização de fios trançados (para diminuir a área susceptível a interferência magnéticas) ao uso de um amplificador diferencial como primeiro estágio na coleta dos dados (US Department of Health and Human Services, 1992; Delsys, 1996). Além das técnicas que garantem maior robustez no canal de condicionamento, é imprescindível a utilização de um filtro capaz de atenuar esse ruído. O filtro pode ser desenvolvido utilizando-se várias técnicas: filtro *notch* analógico, filtros digitais de resposta finita ao impulso (*Finite Impulse Response*, FIR) ou

filtros de resposta infinita ao impulso (*Infinite Impulse Response*, IIR), filtros adaptativos etc. Todas elas devem garantir, considerando que a frequência de 60 Hz esteja dentro da banda de maior concentração de energia do sinal, uma banda de corte a mais estreita possível, para não prejudicar a captação do SME. Outra fonte de ruído origina-se do movimento dos cabos e dos eletrodos de captação de sinal. São os artefatos de movimento. Esses deslocamentos dos eletrodos e o movimento dos cabos geram ruído de baixa frequência relacionado com a variação da tensão média do SME, que afeta o processo de aquisição, pois altera suas características. A faixa de frequência dos mesmos é baixa, e com a utilização de um filtro passa-alta, é possível atenuar a ação desse ruído. É recomendado o uso de um filtro passa-alta com frequência de corte igual a 20 Hz para evitar a influência no processo de aquisição da taxa de disparo das unidades motoras (Delsys, 1996, SENIAM, 2008).

## **2.5- DIGITALIZAÇÃO DOS SINAIS MIOELÉTRICOS**

Para garantir um sistema apropriado de conversão analógico-digital (A/D), são importantes três fatores (Delsys, 2003; Konrad, 2005): o ganho do sistema; o ruído de entrada do sistema e a máxima tensão de saída do sistema.

O conhecimento da amplificação total do sistema é importante para o relacionamento dos sinais de entrada e saída. A seleção do ganho para o sistema de condicionamento é determinada pela faixa de amplitude dos sinais de entrada. De maneira geral, no projeto do sistema de instrumentação biomédico as fontes de ruído radiadas e as do ambiente podem ser controladas pela metodologia de aquisição, embora o ruído intrínseco do equipamento de eletromiografia vá mais longe que o controle do usuário, sendo determinado pelo projeto e construção do equipamento. A seleção dos componentes eletrônicos é um requisito muito importante para obter baixos níveis de ruído. Delsys (2003), sugere conectar as entradas dos eletrodos de eletromiografia ao potencial de referência e verificar a saída do amplificador *Front-end* referida à entrada (dividindo pelo o ganho de todo o canal). Alguns equipamentos de eletromiografia têm registrado níveis na linha base com amplitudes de 5  $\mu$ V (Delsys, 2003). A máxima tensão de saída do sistema

deve ser estabelecido em função da faixa dinâmica do conversor A/D e sua resolução (número de bits) para garantir uma ótima resolução dos sinais mioelétricos.

Um filtro *antialiasing* é utilizado, considerando que a faixa de interesse do sinal é de 20 Hz - 500 Hz. Todo canal de eletromiografia deve prover um filtro *antialiasing*, com frequência da banda passante de 500 Hz. Embora o SME contenha a maior concentração de energia dentro da faixa de 50 Hz até os 150 Hz (Delsys, 1996), é recomendável que a frequência de amostragem seja ao menos de 1000 Hz, como se postula no teorema de *Nyquist* (Delsys, 2003). Um aspecto importante na escolha do conversor A/D é a resolução a utilizar. Tendo em conta os níveis na faixa de amplitude do sinal mioelétrico, é necessária a utilização de conversores A/D com capacidade de aquisição de 12-16 bits para garantir uma boa resolução no sinal mioelétrico. Sistemas de aquisição com menos de 12 bits de resolução podem apresentar limitações quando se coletam baixos níveis de sinais mioelétricos (Delsys, 2003; Merletti e Parker, 2004; SENIAM, 2008).

## **2.6- USO DOS SINAIS MIOELÉTRICOS EM PRÓTESES ATIVAS**

As próteses ativas com controle mioelétrico têm encontrado vantagem sobre outros tipos de próteses dada a natureza autônoma do controle. Os sinais mioelétricos que são coletados na superfície da pele fornecem informação sobre a atividade neuromuscular em uma forma não invasiva e se transformam em um controle importante e efetivo para as próteses ativas. O reconhecimento de padrões mioelétricos consegue discriminar entre diferentes classes de ativações de membros, desenvolvendo funções importantes no controle avançado de próteses ativas para indivíduos com amputações ou com membros congenitamente deficientes (Huang *et al.*, 2005).

Desde a década de 60, sinais mioelétricos têm sido utilizados como sinal de controle para próteses movidas por motores elétricos, ou em músculos que sofreram paralisia. Na Inglaterra, Bottomley aplicou o controle por técnicas de processamento de sinais (Bottomley, 1955). O primeiro sistema comercial controlado foi uma mão produzida pelos russos (Kobriniski *et al.*, 1960), com exportação para a Europa e América do Norte. Dorcas e Scott (1966), do Canadá, desenvolveram um método que veio a ser conhecido

como controlador mioelétrico de três estados, que permitiu o controle de um dispositivo de três funções em um único músculo. Alguns trabalhos baseados em controle mioelétrico foram desenvolvidos na Suécia (Herberts, 1969). Nos Estados Unidos foi desenvolvida a primeira prótese mioelétrica controlada de cotovelo (Mann, 1981). As pesquisas no Japão foram dirigidas ao desenvolvimento de uma mão mioelétrica multifuncional (Merletti e Parker, 2004). Os primeiros controladores mioelétricos foram desenvolvidos em modo *on-off*, para controlar mãos eletricamente com funções de abertura e fechamento. Um canal mioelétrico foi requerido para cada uma das funções, como um controlador de dois músculos. Avanços técnicos aconteceram durante os anos a seguir com produções comerciais e desenvolvimentos tecnológicos nos algoritmos mioelétricos.

Os algoritmos mioelétricos podem ser divididos em sistemas baseados em reconhecimento de padrões e aqueles em que não se empregam as ferramentas de reconhecimento (Oskoei e Hu, 2007). No primeiro grupo, as classes desejadas são discriminadas a partir de padrões de sinais por classificadores, e a variedade das funções depende do desempenho da classificação. Por sua vez, os sistemas que não são embasados em reconhecimento de padrões são implementados utilizando-se para o controle um nível de limiar e máquina de estados finitos. A Figura 2.5 apresenta um diagrama em blocos esquemático dos elementos essenciais em um sistema de controle mioelétrico. A conexão direta é o canal mioelétrico que, em geral, representa uma substituição do sistema de controle do motor. Esses dispositivos geralmente são integrados pelo sinal fisiológico de controle (SME), uma fase do controle do processo, onde o sinal mioelétrico é analisado e transforma-se em comandos de controle do dispositivo de prótese. Todas estas fases são unidas através de retroalimentação e algoritmos adaptativos nas fases de controle do processo (Oskoei e Hu, 2007).

### **2.6.1– O problema da classificação de padrões mioelétricos**

A Figura 2.6 mostra os componentes principais de um algoritmo mioelétrico baseado em reconhecimento de padrões. Os sinais mioelétricos são coletados pelos eletrodos de superfície, localizados na pele sobre o músculo. O sinal proveniente dos eletrodos de superfície é pré-amplificado e, posteriormente, será amplificado, filtrado e

digitalizado. Finalmente, a informação se transfere ao algoritmo mioelétrico que envolve as seguintes fases (Oskoei e Hu, 2007):

- **Segmentação dos dados:** Inclui algumas técnicas e métodos que serão utilizados para manipulação dos dados antes da extração de características, com o objetivo de melhorar a exatidão e a resposta no tempo.
- **Extração de características:** As variáveis que foram medidas externamente e que são apropriadas para a identificação de características significativas no processo de classificação são selecionadas. Novas variáveis podem ser obtidas por transformações lineares ou não-lineares dos dados originais.
- **Classificação:** O módulo reconhece os padrões de sinais e classifica os mesmos em categorias predefinidas. Considerando a complexidade dos sinais biológicos e a influência das condições fisiológicas, o classificador deve ser adequado, robusto, inteligente e ser capaz de se adaptar às próprias mudanças durante longas operações, fazendo uso dos treinamentos *off-line* e *on-line*.

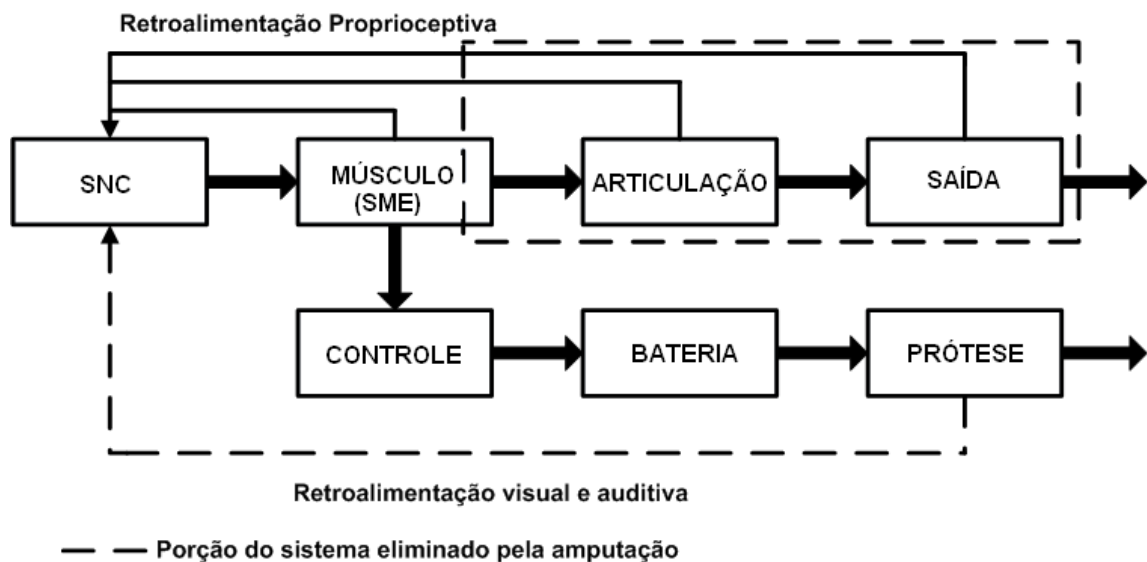


Figura 2.5 - Diagrama de blocos que apresenta a relação entre um sistema normal (indivíduo sem amputação) e mioelétrico (prótese ativa). Adaptado de (Oskoei e Hu, 2007).



O algoritmo mioelétrico deve proporcionar uma alta flexibilidade no controle, com alto grau de desempenho. No processo de projeto e implementação de um controlador mioelétrico, três aspectos importantes são (Englehart e Hudgings, 2003; Oskoei e Hu, 2007): a exatidão na seleção do movimento, implementação intuitiva da atuação do controle e tempo de resposta do sistema. A exatidão do sistema é essencial para uma realização realística da intenção do usuário, sendo um fator importante no desenvolvimento de controladores multifuncionais, a qual pode ser melhorada extraindo mais informação a partir do estado dos músculos e adotando um classificador que seja capaz de aperfeiçoar essa informação. O algoritmo deve ser capaz de aprender os padrões de ativação musculares que são utilizados de forma natural para os movimentos, melhorando em robustez contra as condições de variação, durante a operação. O tempo de resposta não pode criar demoras que sejam perceptível pelo usuário. Dada a característica de tempo real, o tempo de processamento e a geração dos comandos de controle devem ser menores ou iguais a 300 ms (Huang *et al.*, 2005). Até o momento, não foi possível obter um parâmetro único que quantifique as características do sinal mioelétrico adquirido. Com isso, é necessário escolher um grupo de características para o processo de classificação (Oskoei e Hu, 2007).

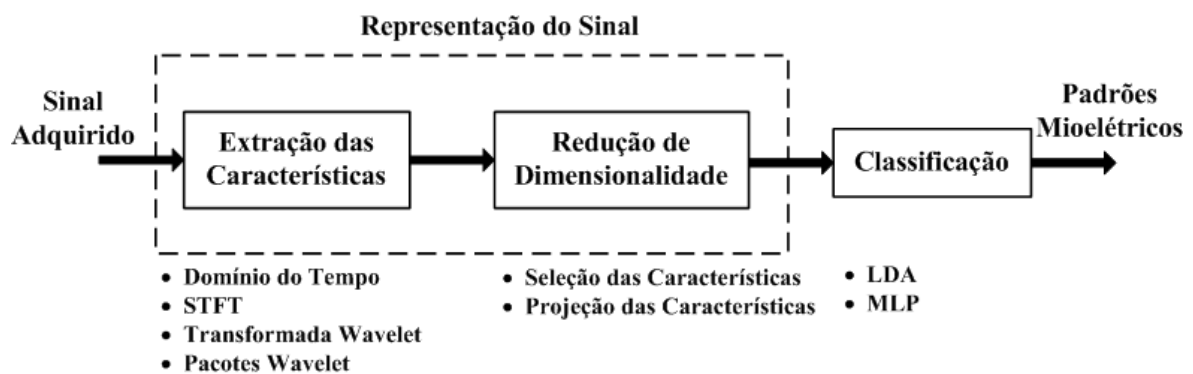


Figura 2.6 - Sistema do controle mioelétrico baseado em reconhecimento de padrões.

### 2.6.2- A segmentação dos dados

Um segmento de dado é uma janela de aquisição de dados mioelétricos, sobre a qual posteriormente será efetuada a realização da extração das características (Oskoei e Hu, 2007). Considerando que o SME contém áreas de inatividade, é importante encontrar

exatamente quando começa a atividade do SME. Alguns autores utilizam uma pequena janela de pontos e empregam métodos paramétricos como a integral de EMG (Hang-Pang e Chun-Yen, 1999), o valor absoluto médio do sinal (Kang *et al.*, 1995) e a entropia do sinal mioelétrico (Ito *et al.*, 2008), fixando determinados limiares que determinam quando a condição do início da contração muscular será satisfeita. A extensão do segmento deve ser adequada para evitar que a variância das características se acumule, degradando o desempenho da classificação. Porém, deve existir um compromisso entre o tempo de resposta e a exatidão (Oskoei e Hu, 2007). Os sinais mioelétricos contêm dois estados: o estado transitório, onde se produz a ativação das fibras quando o músculo vai de repouso a um nível de contração voluntário; o estado permanente, onde acontece uma contração que se mantém constante no músculo (Oskoei e Hu, 2007). Embora os parâmetros extraídos de um estado transitório dos sinais mioelétricos mostrem alta capacidade de classificação, devido às características determinísticas do sinal dentro os primeiros 200 ms, tem desvantagem no controle mioelétrico já que deve ser iniciado do repouso. Isto impede que as mudanças de um padrão mioelétrico para outro sejam detectadas, assim como a coordenação de tarefas complexas que envolvem múltiplos graus de liberdade (Hudgings *et al.*, 1993). Englehart (2001) demonstrou que os dados em estado permanente são classificados com maior exatidão que os dados em estado transitório e sofrem menor degradação para segmentos curtos. A taxa de erro da classificação degrada-se mais rapidamente em segmento de dados em estados transitórios do que em estados permanentes. Janelas de dados com duração de 128 ms em estados permanentes apresentam maior confiabilidade quando se precisa uma rápida resposta do sistema, veja Figura 2.7 (Oskoei e Hu, 2007).

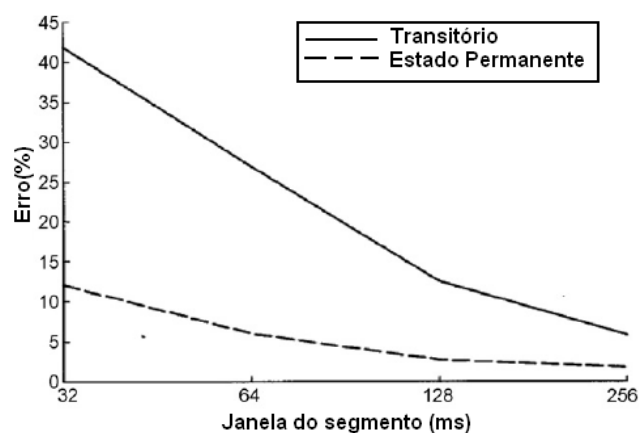


Figura 2.7 - Erro de classificação de padrões mioelétricos comparando o comprimento do segmento em estado transitório e permanente. Adaptado de (Oskoei e Hu, 2007).

Depois da seleção do comprimento do segmento, um aspecto importante é escolher o tamanho da janela para o processamento dos dados. As técnicas principais são janelamento adjacente e sobreposto. No janelamento adjacente, segmentos de dados adjacentes com comprimento predefinido são utilizados para a implementação da extração de características, e uma intenção de movimento classificada pode se originar depois de certo processamento. Na segunda técnica, os novos segmentos se deslocam sobre o segmento atual com um incremento de tempo menor que o comprimento do segmento (Oskoei e Hu, 2007). Englehart e Hudgins (2003) pesquisaram sobre o efeito de incrementar o segmento; um pequeno incremento do mesmo traz consigo um fluxo de classes de decisões mais denso, que pode melhorar o tempo de resposta e a exatidão. Farina e Merletti (2000) mostraram que os segmentos sobrepostos podem incrementar o tempo de processamento sem proporcionar uma melhoria significativa na exatidão das características espectrais. A segmentação contínua foi uma técnica apresentada pelo Englehart e Hudgins (2003). Essa técnica utiliza todos os recursos computacionais do sistema de processamento para produzir resultados de classificação de forma rápida. O fluxo de decisões produzido emprega os segmentos sobrepostos utilizando estados transitórios e permanentes do sinal mioelétrico. Quando os controladores mioelétricos são projetados para sistemas embarcados, é muito importante analisar as implicações causadas pela exatidão e seleção de pequenos comprimentos de segmentos, dado que a variância dos parâmetros característicos aumenta com o decremento do comprimento da janela, e conseqüentemente se degrada o desempenho da classificação do algoritmo mioelétrico (Oskoei e Hu, 2007). No entanto, dados os requerimentos de tempo real, a soma do comprimento do segmento, mais o tempo de processamento dos diferentes estágios que compõem o algoritmo mioelétrico e a geração do comando do controle deve ser igual ou menor que 300 ms, para estabelecer um compromisso entre tempo de resposta e exatidão (Huang *et al.*, 2005; Oskoei e Hu, 2007).

### **2.6.3– Extração de características**

Apresentar um sinal mioelétrico diretamente a um classificador resulta em algo pouco prático, devido à dimensão e às características aleatórias do sinal. É necessário que a sequência do sinal seja representada por um vetor de dimensão reduzida, denominado vetor

característico (Merletti e Parker, 2004). A extração de características é crítica no sucesso de qualquer problema de reconhecimento de padrões, e a mesma depende inteiramente da qualidade e otimização com que se implementa esse estágio (Oskoei e Hu, 2008). A extração de características possui três categorias de análise: análise no domínio do tempo, análise no domínio da frequência (espectral) e análise no domínio do tempo-escala (Oskoei e Hu, 2007). Há dois enfoques para a avaliação da extração de características: a estrutural e fenomenológica. O enfoque estrutural pode ser avaliado através de sinais sintéticos, gerados por modelos matemáticos. As três categorias mencionadas anteriormente podem ser avaliadas a partir do enfoque estrutural (Oskoei e Hu, 2007). O sinal mioelétrico pode ser considerado uma superposição de potenciais de ação individuais gerados pela descarga irregular das unidades motoras. Merlo *et al.* (2003) modelaram um sinal mioelétrico de superfície da seguinte maneira:

$$\begin{aligned}
 s(t) &= \sum_j MUAPT j(t) + n(t) \\
 &= \sum_j \sum_i k_j f\left(\frac{t - \theta_{ij}}{\alpha_j}\right) + n(t),
 \end{aligned}
 \tag{2.1}$$

no qual,  $k_j$  é um fator de amplitude para a  $j$ -ésima unidade motora,  $f_i$  é a forma da descarga do potencial de ação,  $\theta_{ij}$  o tempo de ocorrência do MUAP,  $\alpha_j$  um fator de escala e  $n(t)$  é o ruído. A amplitude e o espectro de potência são as duas características principais utilizadas no processo de extração de características. A amplitude está relacionada com a análise no domínio do tempo, e o espectro de potência com a análise no domínio da frequência (Zecca *et al.*, 2002). Na aproximação fenomenológica, as características são avaliadas principalmente pelo desempenho do classificador e sua robustez (Oskoei e Hu, 2007).

#### 2.6.3.1 – Análise no domínio do tempo

Devido à sua simplicidade computacional, as características no domínio do tempo são muito utilizadas na classificação mioelétrica, e são baseadas na amplitude do sinal (Zecca *et al.*, 2002). A amplitude é proporcional ao número das unidades motoras, e sua taxa de ativação representa a energia do sinal, os níveis de ativação e força (Zecca *et al.*,

2002). Entre os métodos tradicionais no domínio do tempo utilizados na extração de característica, encontramos os descritos a seguir.

**Valor RMS (*Root Mean Square*):** O valor RMS permite caracterizar o sinal de acordo com a estimativa da quantidade de energia, relacionada com sua amplitude, em certo intervalo de tempo. Para um sinal discreto que consiste em  $N$  amostras igualmente espaçadas,  $x(k)$ , a estimativa destes dados algébricos é dada pela seguinte Equação (Farfán *et al.*, 1995):

$$\hat{x} = \sqrt{\frac{1}{N} \sum_{k=1}^N [x(k)]^2} \quad k=1,2,\dots,N, \quad (2.2)$$

no qual,  $N$  é o número total de amostras  $x(k)$  do sinal e RMS é a estimativa de energia.

**Valor Médio absoluto (*Mean Absolute Value*, MAV):** É uma estimativa do valor médio absoluto do sinal  $x(k)$  com  $N$  amostras de comprimento. A estimativa desses dados é dada por (Farfán *et al.*, 1995):

$$\overline{X} = \frac{1}{N} \sum_{k=1}^{N-1} |x(k)| \quad (2.3)$$

**Variância Amostral (VAR):** O parâmetro é utilizado para estimar a densidade de potência do sinal mioelétrico no segmento  $i$  para  $N$  número de amostras. Sua definição é dada por (Farfán *et al.*, 1995):

$$\begin{aligned} \sigma_i^2 &= \frac{1}{N-1} \sum_{k=0}^{N-1} (x(k) - \bar{x}(i))^2 \\ \bar{x}(i) &= \frac{1}{N} \sum_{k=0}^{N-1} x(i-k) \end{aligned} \quad (2.4)$$

**Valor da Integral do sinal mioelétrico (*Integrated EMG, IEMG*):** Este parâmetro calcula a soma dos valores absolutos dos sinais mioelétricos e pode ser tratado como um estimador de potência do sinal. É definido por (Hang-Pang e Chun-Yen, 1999):

$$IEMG = \sum_{k=1}^N |x(k)| \quad (2.5)$$

**Número de cruzamentos por zero (*Zero- Crossings, ZC*):** É uma medida de frequência que pode ser obtida contando o número de vezes que a onda passa por zero. Um limiar ( $\alpha$ ) deve ser incluído para reduzir o ruído induzido no cálculo do *zero-crossings*. Sua equação é dada por (Hang-Pang e Chun-Yen, 1999):

$$ZC = \sum_{k=1}^N \text{sgn}((x(k) - \alpha) \times (x(k-1) - \alpha)) \quad (2.6)$$

$$\text{sgn}(x) = \begin{cases} 1, & \text{se } x > 0 \\ 0, & \text{senão} \end{cases}$$

**Amplitude Willison (*Willison Amplitude, WAMP*):** Este parâmetro é utilizado para contar o número de vezes que o sinal excede um limiar ( $\alpha$ ) predefinido. O parâmetro é um indicador da ativação dos MUAP e, portanto, um indicador dos níveis da contração muscular. O mesmo pode ser formulado por (Hang-Pang e Chun-Yen, 1999):

$$WAMP = \sum_{i=1}^N f(|x(i) - x(i+1)|) \quad (2.7)$$

$$f(x) = \begin{cases} 1, & \text{se } x > \alpha \\ 0, & \text{senão} \end{cases}$$

**Valor das Mudanças do sinal de inclinação:** Este é outro parâmetro que representa a informação de frequência. Como foi mencionado anteriormente, um limiar ( $\alpha$ ) deve ser disponibilizado para rejeitar os efeitos do ruído. O critério para a escolha do parâmetro é definido pelas amostras consecutivas como (Hang-Pang e Chun-Yen, 1999):

$$[x(k)-x(k-1)] \times [x(k)-x(k+1)] \geq \alpha, \quad (2.8)$$

se a condição é satisfeita, o sinal da inclinação muda, e o valor é incrementado.

**Valor do Comprimento da forma de onda (*Waveform Length, WL*):** WL é uma variação acumulativa do SME, que pode indicar seu grau de variação. Sua fórmula é dada por (Hang-Pang e Chun-Yen, 1999):

$$WL = \sum_{k=1}^{N-1} |x(k+1) - x(k)| \quad (2.9)$$

**Entropia do SME:** O enfoque é baseado na diferença em entropia entre o SME em estado estacionário (estado de repouso) e em estado de movimento. Assumindo que o sinal mioelétrico pode ser aproximado por um processo de distribuição normal com média zero, a entropia do SME pode ser calculada como (Ito *et al.*, 2008):

$$H(\sigma_i) = \frac{1}{2} \log_2(2\pi e \sigma_i^2) \quad (2.10)$$

$$\sigma_i^2 = \frac{1}{N-1} \sum_{n=1}^N x_i(n)^2, \quad (2.11)$$

no qual,  $\sigma_i^2$  representa a variância estimada do sinal mioelétrico a partir de cada eletrodo e  $x_i(n)$  é um vetor que contém  $N$  amostras do SME para cada  $i$ -ésimo eletrodo. Para cada canal do SMES, a entropia é calculada e concatenada com o vetor característico de coeficientes cepstrais.

Estas características são extraídas a partir de cada segmento para criar um conjunto total de características que representa um padrão mioelétrico. O efeito do comprimento do segmento na exatidão da classificação deve ser examinado para encontrar um compromisso entre a estimação de classe e o erro de estimação. Quando o tipo de contração é isométrica (exercício de contração estática do músculo, sem movimento visível no ângulo da junta), de força constante e sem processo de fadiga, é assumido que a

amplitude no sinal mioelétrico permanece constante (Merletti e Parker, 2004). Para avaliar o desempenho dos estimadores de amplitude, utiliza-se um indicador SNR (*Signal-Noise Rate*), definido como o valor médio das amostras num segmento dividido pelo seu desvio padrão (Merletti e Parker, 2004; Oskoei e Hu, 2007, sendo que altos SNRs oferecem melhores características.

Geralmente, no processo de extração de características, os parâmetros temporais são mesclados com outros métodos para aumentar a exatidão. Trabalhos desenvolvidos em Farfán *et al.* (1995), durante o movimento de abdução do braço, reportam que estimadores como RMS, VAR e MAV contêm informação suficiente para classificação em posições angulares menores que 50 graus. Os estudos implementados reportaram que estes estimadores são mais eficientes à medida em que se aumenta o segmento do sinal para suas estimações. Melhores desempenhos na separabilidade dos *clusters* (vetores característicos, associados a um padrão mioelétrico) são obtidos com as combinações de IEMG, VAR, WL e WAMP (Hang-Pang e Chun-Yen, 1999).

Embora a função de densidade de probabilidade do SME seja presumivelmente Gaussiana, em alguns casos observa-se que a função é próxima de ser Laplaciana (Figura 2.8), dependendo do nível de contração máxima voluntária (ou o número de unidades motoras ativas) (Oskoei e Hu, 2007). Em baixos níveis de contração muscular ou na ocorrência de processos de fadiga muscular, a distribuição de densidade é próxima de ser Laplaciana (Clancy *et al.*, 2002). Uma técnica baseada em estatística de alta ordem é utilizada para caracterizar os potenciais de ação das unidades motoras. Sua implementação está baseada nas análises dos momentos de primeira e segunda ordem, nas medidas estatísticas (média, correlação e variância) e em suas representações espectrais. Assumindo que as séries temporais apresentam média zero, as estatísticas de alta ordem podem ser determinadas como (Nazarpour *et al.*, 2007):



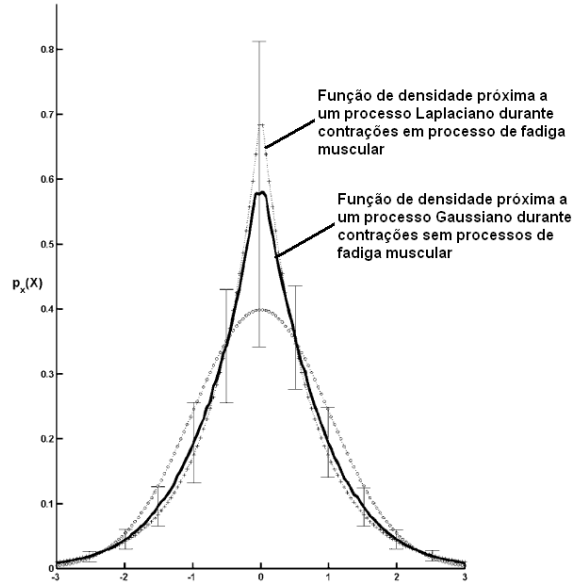


Figura 2.8 - Estimativa da função de densidade de probabilidade normalizada do SME. Adaptado de (Clancy *et al.*, 1995).

$$C_{2,x}(\tau_1) = E\{x(t)x(t+\tau_1)\} \quad (2.12)$$

$$C_{3,x}(\tau_1, \tau_2) = E\{x(t)x(t+\tau_1)x(t+\tau_2)\} \quad (2.13)$$

$$C_{4,x}(\tau_1, \tau_2, \tau_3) = E\{x(t)x(t+\tau_1)x(t+\tau_2)x(t+\tau_3)\} \quad (2.14)$$

$$-C_{2,x}(\tau_1)C_{2,x}(\tau_2 - \tau_3)$$

$$-C_{2,x}(\tau_2)C_{2,x}(\tau_3 - \tau_1)$$

$$-C_{2,x}(\tau_3)C_{2,x}(\tau_1 - \tau_2),$$

no qual,  $C_{i,j}$  e  $\tau_i$  são as estatísticas e os retardos de tempo, respectivamente. Os resultados obtidos em (Nazarpour *et al.*, 2007) mostram que as estatísticas de alta ordem podem ser utilizadas para resolver os problemas de classificação de padrões de movimentos do cotovelo e do antebraço. Além disso, uma combinação seletiva das estatísticas obtidas através de métodos de redução de dimensionalidade do espaço característico (Nazarpour *et al.*, 2007) podem significativamente reduzir o custo computacional. Este método exibe alta exatidão na classificação de segmentos de eletromiografia, registrados em baixos níveis de força muscular.

### 2.6.3.2 – Análise no domínio da frequência (análise espectral)

O espectro do sinal é influenciado por dois fatores: a taxa de ativação das unidades motoras ativadas na faixa de baixa frequência (abaixo de 40 Hz) e a morfologia dos potenciais de ação que viajam ao longo da fibra muscular na faixa de alta frequência (acima de 40 Hz) (Karlsson *et al.*, 1999). O mesmo é variante no tempo e depende diretamente da força de contração, da fadiga muscular e da distância inter-eletrodo (Oskoei e Hu, 2007). Foi mostrado em (Karlsson *et al.*, 2000) que o sinal mioelétrico em baixos níveis (20% a 30% de contrações máximas voluntárias) e em contrações de tempo curto, de 20 a 40 s, pode ser assumido como estacionário no sentido amplo. Já em altos níveis (50% a 80% de contrações máximas voluntárias), esta pode ser assumido localmente estacionário por um período de 500 a 1500 ms.

A densidade espectral de potência (*Power Spectral Density*, PSD) desempenha um papel importante na análise espectral. A densidade espectral é definida como a Transformada de Fourier da função da autocorrelação, sendo amplamente utilizada por vários métodos. Quando a PSD é estimada empregando-se o quadrado da transformada de Fourier dividido pelo comprimento do sinal, ela apresenta vários problemas como: vazamento de frequência relacionado ao pré-janelamento, resolução de frequência relacionada com o curto segmento de tempo para garantir a estacionaridade do sinal e a superposição da periodicidade do sinal (Oskoei e Hu, 2007).

Uma série temporal é uma sequência cronológica das observações de uma variável específica. Dado que as análises das séries de tempo se fundamentam em modelar um sinal como uma combinação linear de seus valores passados e presentes (Hefftner *et al.*, 1988), a natureza estocástica do sinal mioelétrico pode ser considerada como uma série temporal. Existem várias classes de modelos de séries temporais: auto-regressivos (*Autoregressive*, AR), média móvel (*Moving Average*, MA) e auto-regressivo – média móvel (*Autoregressive Moving Average*, ARMA) (Graupe e Cline, 1975; Hefftner *et al.*, 1988). O modelo auto-regressivo representa a estrutura mais conveniente para a identificação do modelo, especialmente quando a velocidade computacional é importante,

como é o caso da discriminação de padrões mioelétricos. Sua fórmula matemática é dada por (Hefftner *et al.*, 1988):

$$y_k = \sum_{i=1}^p a_i y_{k-i} + w_k, \quad (2.15)$$

no qual,  $y_k$  representa o sinal registrado no tempo discreto  $k$ ,  $a_i$  são os parâmetros auto-regressivos,  $w_k$  é o ruído residual branco e  $p$  é a ordem do modelo. Os parâmetros auto-regressivos contêm a informação para modelar em dados o modo de contração muscular. A obtenção destes parâmetros fornecem o conjunto de características para os processos de reconhecimento e classificação (Hefftner *et al.*, 1988). O método paramétrico, a partir de um modelo auto-regressivo utilizado para estimação da densidade espectral de potência, pode evitar as limitações mencionadas em relação à Transformada de discreta Fourier.

Para a determinação dos parâmetros auto-regressivos, os algoritmos adaptativos mais utilizados são o método da mínima média quadrada (*Least Mean Square*, LMS) e o método dos mínimos quadrados recursivos (*Recursive Least Square*, RLS). O algoritmo LMS não sofre instabilidade numérica, é relativamente simples de ser implementado, sendo por isso amplamente utilizado (Hang-Pang e Chun-Ye, 1999; Zhao *et al.*, 2005; Doershuk *et al.*, 1983; Heffner *et al.*, 1988). No entanto, para sinais com faixa dinâmica espectral longa, o algoritmo LMS tem uma taxa de convergência desigual e lenta (Vaseghi, 2000). O algoritmo RLS tem uma melhor convergência que o LMS, mas pode sofrer instabilidades numéricas. Como este não é adequado para implementação em tempo real, devido à necessidade da inversão de matriz (Ifeachor e Jarvis, 1993), calculada a cada iteração, utiliza-se método recursivo para estimar os valores dos coeficientes do filtro sem necessidade da inversão de matriz. O método baseou-se no fato de que as informações de maior importância são aquelas mais próximas à amostra considerada atualmente no ciclo de iteração. Consegue-se esta discriminação das amostras com o fator de esquecimento. Como o cálculo dos parâmetros é feito recursivamente, espera-se que o esforço computacional seja reduzido. Para sinais não estacionários, o algoritmo RLS representa uma melhor alternativa de implementação (Vaseghi, 2000).

Os trabalhos desenvolvidos (Doershuk *et al.*, 1983; Hefftner *et al.*, 1988; Huang *et al.*, 2005; Liu *et al.*, 2007) mostram que um modelo auto-regressivo de quarta a sexta ordem é adequado para representar o sinal mioelétrico como uma série temporal. Alguns resultados mostram (Hang-Pang e Chun-Yen, 1999) que os parâmetros apresentam uma ótima separação de *cluster*, quanto maior seja a janela das amostras, e que os primeiros dois parâmetros do modelo AR têm melhor separação dos *clusters* que os dois últimos, quando se trabalha com modelos de quarta ordem. Outras combinações, como IEMG, Variância, WL, WAMP, ZC e modelos AR de segunda ordem apresentam resultados satisfatórios em relação ao desempenho de classificação (Hang-Pang e Chun-Yen, 1999). Para reduzir o custo computacional, os modelos auto-regressivos de ordem seis são adequados para aplicações de tempo real com comprimento de segmentos de 250 ms. Em condições não estacionárias é recomendável um comprimento de segmento de 250 a 500 ms para reduzir a estimação da variância (Oskoei e Hu, 2007). Huang *et al.* (2005), compararam um grupo de características no domínio do tempo e frequência. Os resultados mostram que a combinação de RMS com os coeficientes auto-regressivos de ordem seis oferecem alto desempenho e implementações como AR+RMS e AR+RMS+MAV+VAR+IEMG resultam em taxas de erros médios de classificação de 3,7% e 3,1%, respectivamente.

São também obtidos, a partir dos métodos paramétricos, os coeficientes cepstrais (*Cepstral Coefficients* - CEP), que contêm informações sobre o espectro do sinal. A função Cepstrum é definida como a transformada inversa do logaritmo do espectro de potência do sinal. Para uma função de transferência, composta apenas por pólos, o primeiro coeficiente cepstral pode ser obtido diretamente a partir dos coeficientes AR ( $a_1, \dots, a_p$ ) de um modelo de  $p$ -ésima ordem. Em seguida, pode-se calcular o resto dos coeficientes da seguinte maneira (Farfán *et al.*, 1995, Kang *et al.*, 1995):

$$\begin{aligned}
 C_1 &= -a_1 \\
 C_i &= -a_i - \sum_{n=1}^{i-1} \left(1 - \frac{n}{i}\right) a_n c_{i-n} \quad l < i \leq p
 \end{aligned}
 \tag{2.16}$$

Uma comparação empregando os coeficientes auto-regressivos e cepstrais, juntamente com a utilização de algoritmos de classificação como: Medida da Distância Euclidiana (*Euclidean Distance Measure*, EDM), Medida da Distância dos Pesos (*Weighted Distance Measure*, WDM) e Método de Máxima Verossimilhança (*Maximum Likelihood Method*, MLM) (Kang *et al.*, 1995) mostram melhoria estatisticamente significativa neste último, apresentando uma média da taxa de reconhecimento pelo menos 5% superior aos coeficientes auto-regressivos. Os coeficientes cepstrais mostram melhor separação dos agrupamentos no espaço característico e enfatizam diferenças espectrais na faixa de baixa frequência, onde a informação significativa é mais proeminente. Chen *et al.* (2009) implementaram algoritmos mioelétricos com a utilização de coeficientes cepstrais derivados dos discriminantes de Fourier (*Fourier-Derived Cepstrum*, DFC), para efetuar a classificação de onze movimentos da mão e do pulso. Os DFC apresentam a vantagem de fornecerem diretamente as informações dos SMEs no domínio da frequência a partir da grandeza de Fourier e fornecem um uso flexível da informação espectral que muda com os diferentes movimentos (Chen *et al.*, 2009). Em uma comparação para avaliar o desempenho da classificação entre os DFC, os coeficientes cepstrais derivados dos coeficientes auto-regressivos (*Autoregressive-derived cepstrum*, ARC) e as estatísticas no domínio do tempo (*Time domain statistics*, TDS) indicaram que os cepstrum derivados dos discriminantes de Fourier apresentam um ótimo desempenho na razão de classificação com média e desvio padrão de  $96,36\% \pm 1,71$  com respeito aos TDS e ARC de  $94,85 \pm 1,99$  e  $93,65 \pm 2,06$  respectivamente.

#### 2.6.3.3 – Análise tempo-escala

Na análise espectral, a Transformada de Fourier (*Fourier Transform* - FT) é aceitável para sinais estacionários já que suas propriedades (média, autocorrelação e espectro de potência) não mudam no tempo (Oskoei e Hu, 2007). Porém, os sinais mioelétricos contêm numerosas características não estacionárias ou transitórias. A Transformada discreta de Fourier de Curto Tempo (*Short-Time Fourier Transform* - STFT) mapeia um sinal em uma função de duas dimensões, mas meramente obtém informação com exatidão limitada, determinada pelo tamanho da janela de análise (Oskoei e Hu, 2007). Há um compromisso entre a resolução no tempo e frequência. Para

incrementar a resolução no tempo, pequenos segmentos de dados devem ser utilizados, os quais reduzem a resolução da FT resultante (Ferguson e Dunlop, 2002).

Na análise da transformada *wavelet* (*Wavelet Transform* - WT), há uma correspondência entre a escala e a frequência: uma baixa escala mostra detalhes de mudanças rápidas no sinal com alta frequência. Uma alta escala mostra mudanças lentas com baixas frequências (Ferguson e Dunlop, 2002; Englehart *et al.*, 2001, Maitrot *et al.*, 2005; Liu, 2005; Ren *et al.*, 2006; Lucas *et al.*, 2007; Hussain *et al.*, 2009). Adicionalmente, a análise *wavelet* pode comprimir e eliminar o ruído no sinal sem uma apreciável degradação através da *Wavelet de-noising* (Guang-ying e Zhi-zeng, 2004; Phinyomark *et al.*, 2009). Uma generalização da transformada *wavelet* é o de pacotes *wavelet*, (*Wavelet Packets Transform*, WPT), que permite uma melhor adaptação do sinal no domínio tempo-escala (Wang *et al.*, 2006).

A diferença fundamental entre a STFT, WT e a WPT está na forma da divisão tempo-escala. A STFT tem uma razão de divisão fixa; cada escala tem uma taxa de aspecto idêntica no tempo e frequência. A taxa de divisão da WT é variável; a taxa de aspecto das células varia tal que a resolução de frequências é proporcional à frequência central. A WPT possibilita uma divisão adaptativa. Um conjunto completo de partições é disponibilizado como alternativas, e a melhor adaptação para uma aplicação é escolhida.

Foram realizadas implementações utilizando as características no domínio do tempo (*Time Domain*, TD), transformada de Fourier de curto tempo, transformada *wavelet* e transformada *wavelet packets*, empregando dados coletados a partir de dois canais (músculos do bíceps e tríceps) para a discriminação entre quatro classes de movimentos (Englehart *et al.*, 2001). Os resultados apresentam uma melhoria no desempenho na seguinte progressão: TD→STFT→WT→WPT. Em relação ao número de canais mioelétricos empregados na classificação, resultou que um sistema com quatro canais, usando a WPT apresenta 0,5% na taxa de erro da classificação quando se discriminam quatro classes, e 2% na taxa de erro com seis classes. Ambas as taxas de erro são consideradas suficientemente baixas para o número de classes a discriminar. Os testes realizados nos sujeitos foram mais precisos utilizando um sinal em estado permanente que

em estado transitório. Diferentemente dos métodos tradicionais no domínio do tempo, os quais empregam detecção de amplitude como extração de característica significativa, o método de transformada *wavelet*, que utiliza filtro de amplitude a partir de limiares (Ren *et al.*, 2006; Guang-ying e Zhi-zeng, 2004) (*Wavelet denoising*), apresenta resultados, em relação ao tempo de extração, consistentemente menores que os métodos tradicionais. Ao mesmo tempo, esta técnica é mais robusta devido ao seu processo de decomposição que pode efetivamente eliminar ruídos potenciais gerados no sinal mioelétrico (Guang-ying e Zhi-zeng, 2004).

Hussein e Granat (2002) utilizaram uma técnica que reduz o tempo de atraso global e melhora o tempo de análise espectral. O método é denominado *Gabor Matching Pursuit* (GMP), sendo utilizado para uma estimação eficiente de um sinal aproximado por uma combinação linear das funções básicas, que são chamadas átomos. No método proposto, os átomos são selecionados a partir de um dicionário *Gabor*, e parâmetros são calculados por um procedimento de casamentos de padrões. Na classificação, os parâmetros dos átomos são interpretados como características do sinal. Embora o algoritmo GMP seja considerado de sucesso, o mesmo sofre de complexidade computacional elevada.

#### 2.6.3.4 – Análises fenomenológicas

O tema comum nas análises fenomenológicas é a geração de um conjunto de características que melhora o desempenho na classificação do sinal. Este último pode ser considerado de duas formas: seleção de um subconjunto característico e projeção de características (Oskoei e Hu, 2007). A seleção de um subconjunto característico requer de uma estratégia de pesquisa e uma função objetivo que avalie os candidatos. A função pode ser uma medida de separação geométrica ou um indicador da taxa final dada do classificador (Oskoei e Hu, 2007). Uma das estratégias mais utilizadas no controle mioelétrico é a estratégia de pesquisa aleatória e, em especial, os algoritmos genéticos (*Genetic Algorithm*, GA, Han-Pang *et al.*, 2003; Oskoei e Hu, 2006; Peleg *et al.*, 2002). Trabalhos como Oskoei e Hu (2006), que adotam algoritmos genéticos como estratégias de teste, fazem uso do índice *Davies-Bouldin*, do índice de discriminante linear *Fisher* e da

análise de discriminante linear (*Linear Discriminant Analysis*, LDA). Os resultados mostram que o subconjunto baseado no índice *Davies-Bouldin*, utilizado como função-objetivo, apresenta melhorias consideráveis de classificação, com taxas de erros da classificação de 3,93% e 5,27% com LDA e Redes Neurais Artificiais (*Artificial Neural Networks*, ANN), respectivamente, como estágios de classificação. No entanto, o subconjunto baseado em LDA como função-objetivo apresenta o pior desempenho para classificadores ANN, com taxa de erro da classificação de 21,23%.

A projeção de características é mais aplicada a problemas de redução de dimensionalidade que se apresentam quando se emprega extração de características tempo-escala. A transformada *wavelet* gera muitos coeficientes para representar as características tempo-escala. As mesmas precisam ser mapeadas em baixa dimensão preservando-se a informação mais discriminativa. Englehart *et al.* (2001, 1999), apresentaram uma pesquisa comparativa em projeção linear comparando o desempenho de análises baseadas em características temporais (Hudgings *et al.*, 1993) e características tempo-escala que utilizam a STFT, WT e a WPT. As características tempo-escala foram reduzidas usando análises de componentes principais (*Principal Components Analysis*, PCA), e os resultados obtidos mostram superioridade deste método com respeito a outros métodos de redução (Hargrove *et al.*, 2009). O melhor desempenho foi obtido com a extração de características de WPT, PCA como redução de dimensionalidade, e LDA como método de classificação, com uma taxa de erro médio da classificação de 0,5% para quatro classes e 2% para seis classes. Chu *et al.* (2005), propuseram um método de projeção não linear composto de PCA e mapas auto-organizáveis (*Self Organizing Maps*, SOM). O fundamento do mesmo é que a função de densidade de classe não fica claramente discriminada com a utilização de PCA. Um mapa não-linear por SOM transforma as características PCA, reduzindo-se a um novo espaço de características, melhorando a capacidade de separação de classes. O esquema melhora o desempenho da classificação comparado ao uso de PCA de forma independente. A análise de discriminante linear não-correlacionado (modificação do método LDA) requer que as características transformadas sejam estatisticamente não-correlacionadas, com o objetivo de minimizar a redundância (Khushaba *et al.*, 2009). Experimentos recentes, efetuados em 30 indivíduos saudáveis utilizando o método de



discriminante linear não-correlacionado, apresentaram boas precisões no reconhecimento de padrões mioelétricos, com uma média na exatidão de 92,5% (Chan e Green, 2007).

#### 2.6.4– Índices de desempenho quantitativo do espaço característico

Uma alta qualidade do espaço característico (espaço que agrupa os coeficientes ou vetores característicos, obtidos no estágio de extração de características) deve ter as seguintes propriedades (Zardoshti-Kermani *et al.*, 1995):

1. **Máxima separação das classes:** No espaço característico, os *clusters* devem ter máxima separação, para garantir que os erros por classificação sejam os mais baixos possíveis.
2. **Robustez:** O espaço característico selecionado deve preservar a separação dos *clusters* em ambientes ruidosos.
3. **Baixa complexidade:** A complexidade computacional para obter o espaço característico deve-se manter a mais baixa possível para que os procedimentos possam ser implementados em tempo real.

Para avaliar o espaço característico, há duas aproximações baseadas em uma estimativa da taxa do erro de classificação (*K-Nearest Neighborhood*, KNN) e em uma medida da separação (*Davies-Bouldin*, DB), respectivamente (Zardoshti-Kermani *et al.*, 1995). O método KNN com distância euclidiana, que identifica um evento desconhecido para a classe representada pela maioria de seus vizinhos mais próximos, é um classificador não paramétrico para o qual o limite da taxa de erro está relacionada com a taxa do erro de Bayes (Nazarpour *et al.*, 2007; Zardoshti-Kermani *et al.*, 1995). O método *Davies-Bouldin* é um enfoque paramétrico baseado em medida de separação de *cluster* no espaço característico a partir de matrizes de dispersão. O mesmo requer o cálculo da similaridade de *cluster a cluster* baseada na seguinte expressão (Wang *et al.*, 2006; Oskoei e Hu, 2006; Zardoshti-Kermani *et al.*, 1995):

$$R_{ij} = \frac{(S_i + S_j)}{D_{ij}}, \quad (2.17)$$

no qual,  $S_i$  e  $S_j$  são as dispersões dos *clusters*  $i$  e  $j$ , respectivamente, e  $D_{ij}$  a distância entre seus valores médios. A dispersão de um *cluster* é definida como:

$$S_i = \left\{ \frac{1}{N_i} \sum_{j=1}^{N_i} (y_i - m_i)^T (y_j - m_i) \right\}^{1/2} \quad y_j \in C_i, \quad (2.18)$$

no qual,  $N_i$  é o número de *cluster*  $C_i$ ,  $y_i$  é o vetor padrão de entrada e  $m_i$  é o vetor da média do *cluster*  $i$ . A função de distância entre dois *clusters* pode ser obtida a partir da distância euclidiana:

$$D_{ij} = \left\{ (m_i - m_j)^T (m_i - m_j) \right\}^{1/2} \quad (2.19)$$

O índice DB é obtido pela média do pior caso de separação de cada *cluster* com respeito aos outros, da seguinte forma:

$$DB = \frac{1}{K} \sum_{i=1}^K \max_{i \neq j} (R_{ij}), \quad (2.20)$$

no qual,  $K$  é o número de elementos do *clusters* e o índice DB registra o grau de similaridade do *cluster* com os vizinhos mais próximos. Baixos valores do índice DB significam alto grau de separação entre os *clusters*. A Figura 2.9 apresenta o desempenho de vários métodos de extração de características baseadas em curvas de separação de classes. Os resultados são mostrados para tamanhos de janelas de 10 ms a 200 ms. As curvas de separação de classes, como são mostradas, são uma boa medida para a escolha da janela de dados durante o processo de segmentação dos dados. Quando o tamanho da janela de dados é maior, o desempenho da separação de classe do espaço característico melhora (Zardoshti-Kermani *et al.*, 1995). Na Figura 2.9, o método de histograma de EMG apresenta o melhor desempenho seguido pelos métodos WAMP, operador *log* e operador *v-order*. O primeiro coeficiente auto-regressivo (modelo de quarta ordem) requer de uma

janela mais longa (aproximadamente 140 ms), para obter um desempenho comparável aos outros métodos. O método ZC apresenta a pior separação de classes e consequentemente o pior desempenho de classificação (Zardoshti-Kermani *et al.*, 1995). Alguns experimentos utilizando análises no domínio do tempo e da frequência (ZC, AR, WAMP, VAR e histograma de EMG), com adição de diferentes níveis de ruído, foram testados com vistas à separação dos *clusters* com um tamanho de janela fixo de 100 ms (Zardoshti-Kermani *et al.*, 1995). Os resultados obtidos mostram que o desempenho do ZC, o primeiro coeficiente AR1 e o WAMP se degradam rapidamente com o decremento da SNR. O histograma de EMG e VAR apresentam índices estáveis DB dado às condições de ruído, (Figura 2.10). A Figura 2.10 não foi alterada da versão publicada pelos autores.




Figura 2.9 - Variação da qualidade do espaço característico com o tamanho da janela de dados. Abreviações: integral do sinal mioelétrico (IAV), número de cruzamentos por zero (ZC), variância amostral (VAR), primeiro coeficiente auto-regressivo (AR1), operador *v-order* (V), operador *log* (LOG), amplitude *willison* (WAMP) e histograma de EMG (HIST). Adaptado de (Zardoshti-Kermani *et al.*, 1995).




Figura 2.10 - Variação da qualidade do espaço característico com amplitudes de ruído branco. Adaptado de (Zardoshti-Kermani *et al.*, 1995).

### 2.6.5– Classificação do espaço característico

As características extraídas precisam ser organizadas em classes para o reconhecimento de padrões do movimento desejado. O classificador deve ser capaz de lidar com padrões de variação de forma ótima, tendo em conta as grandes variações que experimenta o sinal mioelétrico a fatores externos, tais como mudanças na posição do eletrodo, fadiga e suor. O classificador deve se adequar rapidamente para cumprir as restrições de tempo real e a eficiência na classificação de novos padrões.

#### 2.6.5.1 – Enfoque em redes neurais

A vantagem das redes neurais é a habilidade para representar relações de forma linear e não-linear, cuja aprendizagem vem diretamente dos dados que estão sendo modelados. As mesmas introduzem restrições de tempo real, as quais são características importantes nos sistemas de controle (Oskoei e Hu, 2007). Hudgins *et al.* (1993) usaram uma rede neural perceptron multicamada (*Multi-Layer Perceptron*, MLP) para classificar características no domínio do tempo. Foram obtidas taxas de erros de classificação de,

aproximadamente, 10% para a classificação de quatro tipos de movimento do membro. Recentemente, Zhao *et al.* (2006), aplicaram um MLP para reconhecer seis movimentos, baseados em análises de tempo-escala e em entropia, e seus resultados apresentaram uma exatidão de aproximadamente 95%. Englehart *et al.* (2001) compararam LDA com MLP como classificador mioelétrico e foi observado que o desempenho do LDA é similar ou melhor que MLP para as características tempo-escala, após reduzida, a dimensionalidade usando PCA. A melhoria pode estar no fato de que o PCA lineariza o conjunto de características. Au e Kirsch (2000) desenvolveram um *Time-Delayed Artificial Neural Network* (TDANN), cujas entradas foram o sinal não processado do SME, e não o vetor característico para prever as variáveis cinemáticas do ombro e cotovelo. A TDANN foi capaz de caracterizar a relação linear e não-linear entre as variáveis de entrada e saída, e seu treinamento foi efetuado através do algoritmo *Back Propagation* até que a soma do erro quadrático entre suas saídas e variáveis cinemáticas ficarem abaixo de um valor limiar. Modificações efetuadas na MLP utilizando *Levenberg-Marquardt* (LM) foram comparadas com o gradiente conjugado e com a taxa de aprendizagem variável (Hagan e Menhaj, 1994). Os resultados indicam que o algoritmo *Levenberg-Marquardt* é muito eficiente quando se treinam redes as quais têm centenas de pesos. O algoritmo *Levenberg-Marquardt* é uma modificação do algoritmo *Gauss-Newton* (Battiti, 1992). A idéia fundamental do algoritmo *Levenberg-Marquardt* é a computação da matriz Jacobiana (Hagan e Menhaj, 1994).

#### 2.6.5.2 – Enfoque por lógica nebulosa

A utilização de sistemas de lógica difusa nebulosa para classificação dos sinais biomédicos tem muitas vantagens, pois os bio-sinais nem sempre se repetem e, algumas vezes, são contraditórios (incompatibilidades lógicas entre duas ou mais preposições) (Constatin, 1995; Khushaba *et al.*, 2009). Os sistemas de lógica difusa toleram contradições atípicas nos dados. Eles são capazes de encontrar padrões que não são facilmente detectáveis. Os sistemas *fuzzy* exploram a tolerância de imprecisão e incerteza para solucionar problemas de classificação com robustez e baixo custo (Oskoei e Hu, 2007). Ajiboye e Weir (2005) trabalharam com um enfoque heurístico *fuzzy* para reconhecimento de padrões mioelétricos multicanais, baseados em uma linguagem simples,

com geração automática para o usuário e executado em tempo real, com tempo de resposta de 45 ms. O classificador proposto contém três partes (como nos sistemas de classificação *fuzzy*), uma função de pertinência de entrada (*input membership function*, IMBF), uma base de regra de inferência (*inference rule base*, IRB) e uma função de pertinência de saída (*output membership function*, oMBF). A IMBF converte a característica do sinal em quatro graus de sinal (*OFF, LOW, MED, HIGH*). A IRB é o cérebro do sistema *fuzzy* que consiste de regras em linguagem vernácula da forma *IF-THEN*. O número de regras depende dos diferentes padrões apresentados dentro do treinamento dos dados, e as regras são geradas automaticamente a partir do algoritmo *fuzzy C-means* (FCM) aplicado ao treinamento dos dados. Park e Lee (1998) adotaram um método de acumulação de evidência (*evidence accumulation*, EA) para a classificação, a partir da teoria *Dempster-Shafer* para estimar a intenção de movimento. Neste método, quatro componentes; *evidence for* (*ef*), *evidence against* (*ea*), *neutral evidence* (*n*) e *contradictory evidence* (*x*) foram utilizados para representar a evidência de um evento. A classe padrão que tem a maior *evidence for* é escolhida para a classe de movimento que corresponde ao sinal de entrada. As componentes de evidência são determinadas usando uma função de mapeamento *fuzzy* aplicada à distância entre o vetor característico e os parâmetros dos limiares obtidos durante o período de treinamento.

### 2.6.5.3 – Enfoque Neuro-*fuzzy*

Karlik *et al.* (2003) propuseram a *Fuzzy Clustering Neural Network* (FCNN) para a classificação. A FCNN fornece dados ao *cluster* sobreposto, com certo grau de pertinência. Isto é, para cada vetor  $x_k$ , uma variável  $0 \leq u_{ik} \leq 1$  pode ser definida para quantificar sua pertinência a um *cluster* com centro  $v_i$ . Para a implementação do *fuzzy cluster*, um algoritmo proposto minimiza a função de custo  $J_m$ :

$$J_m = \sum_{k=1}^N \sum_{i=1}^C (u_{ik})^m \left\| x_k - v_i \right\|_A^2, \quad (2.21)$$

no qual,  $A$  é utilizado para definir a distância entre  $x_k$  e  $v_i$ . Na literatura também se utiliza uma rede neural da função de seção cônica (*Conic Section Function Neural Network*,

CSFNN) como classificador. A CSFNN permite que as superfícies de decisão sejam adaptadas entre limite aberto como em MLP e limites fechados como nas funções radiais (*Radial Basic Function*, RBF), provendo unificação entre a RBF e MLP. A regra de propagação que envolve ambas RBF e MLP é dada por:

$$y_j = \sum_{i=1}^{N+1} (x_i - c_{ij}) w_{ij} - \cos w_j \sqrt{\sum_{i=1}^{N+1} (x_i - c_{ij})^2}, \quad (2.22)$$

no qual,  $w_{ij}$  representa os pesos no MLP e  $c_{ij}$  representa o cluster no RBF. Um estudo em (Karlik *et al.*, 2003) mostra resultados mais confiáveis obtidos usando FCNN, ao contrário da utilização do MLP e CSFNN. Foi demonstrado que o tempo de treinamento de FCNN é a metade do tempo requerido para o MLP. CSFNN com taxa de classificação de 88% não tem resultados de classificação menos satisfatórios em comparação ao MLP e FCNN, que possuem uma taxa de classificação de 97% e 98%, respectivamente.

#### 2.6.5.4 – Enfoque probabilístico

Dado que o sinal mioelétrico é estocástico, uma aproximação probabilística a cada classe pode solucionar alguns problemas de classificação. O modelo de mescla Gaussiana (*Gaussian Mixture Model*, GMM) é uma aproximação probabilística que tem sido usada no reconhecimento de padrões. O modelo é descrito através da Equação:

$$p(\vec{x} | \lambda_n) = \sum_{i=1}^M w_i^n p_i^n(\vec{x}), \quad (2.23)$$

no qual,  $\vec{x}$  representa um vetor característico m-dimensional para o modelo n-ésimo ( $\lambda_n$ ),  $M$  é o número de componentes mesclados,  $w_i^n$  ( $i=1, \dots, M$ ) são os pesos mesclados que satisfazem a condição que  $\sum_{i=1}^M w_i^n = 1$  e  $w_i^n \geq 0$  e  $p_i^n(\vec{x})$  é a função de densidade gaussiana.

O modelo tem a habilidade de formar uma aproximação suave para a função de densidade de probabilidade geral a partir da soma de múltiplas funções gaussianas. Huang *et al.*

(2005) apresentam o potencial do GMM na classificação mioelétrica, baseado em trabalhos preliminares de Chan e Englehart (2003), para aperfeiçoar uma GMM na classificação dos movimentos de membros. N-GMM foram implementados para especificar a probabilidade de cada classe em problemas de N classes. A densidade de probabilidade de GMM, a qual é chamada densidade misturada (*Mixture Density*, MD), é uma combinação linear de múltiplas densidades de probabilidade gaussianas (chamadas componentes), que são parametrizadas por um conjunto de pesos, média de vetores e matrizes de covariância dos componentes. O modelo que gera a mais alta probabilidade determina a classe predita. A função de treinamento estima os parâmetros do GMM com os quais a MD emparelhará melhor a distribuição do conjunto. Os parâmetros anteriores foram estimados usando um algoritmo de *Expectation Maximization*, no qual, GMM, LDA, MLP e perceptron linear (*Linear-Perceptron*, LP) foram utilizados como classificadores para comparar seu desempenho (Huang *et al.*, 2005). Os classificadores foram implementados em pós-processamento em um esquema de classificação contínuo, e o desempenho do GMM foi igual ou maior que os outros classificadores, com 96,3% de taxa de classificação, usando AR+RMS para a discriminação de seis classes.

#### 2.6.5.5 – Enfoque com máquina de vetores de suporte

A máquina de vetores de suporte (*Support Vector Machine*, SVM) proposto por Cortes e Vapnik *et al.* (1995), tem tido aceitação nas aplicações de reconhecimento de padrões (Osuna *et al.*, 1997; Liu e Chen, 2007; Yoshikawa *et al.*, 2007; Oskoei e Hu, 2008). A estratégia de aprendizagem da SVM é baseada no princípio de minimização do risco estrutural (*Structural Risk Minimization*, SRM) que minimiza os erros de treinamento e os erros de generalização entre os limites das classes (Liu *et al.*, 2007). Embora as SVMs tenham sido aplicadas em muitos problemas de classificação, há poucas aplicações das mesmas na classificação dos SMEs. Para sua aplicação no reconhecimento de padrões mioelétricos, são consideradas as seguintes propriedades (Yoshikawa *et al.*, 2007):

1. Alta capacidade de generalização das SVMs, que podem ser utilizadas para classificar padrões mioelétricos com características que mudam no tempo;



2. Capacidade de classificação linear de padrões com baixa carga computacional, permitindo a classificar movimentos em tempo real;

Em uma SVM, a função de decisão da classificação para um vetor  $x$  desconhecido é descrita como (Yoshikawa *et al.*, 2007):

$$f(x) = \text{sgn}\left(\sum_{i=1}^D \lambda_i y_i k(x_i, x) + b\right), \quad (2.24)$$

no qual,  $y_i$  é a classe correspondente à  $i$ -ésima amostra do treinamento  $x_i$ ,  $D$  é o número de amostras do treinamento,  $\lambda_i$  é o multiplicador de Lagrange e  $b$  é um *bias*. Para aplicações de reconhecimentos de padrões mioelétricos, um *kernel* ( $k(x_i, x)$ ) com RBF é dado como sugestão (Oskoei e Hu, 2008). Tendo em conta a seleção do *kernel*, a função de decisão pode ser obtida, solucionando o seguinte problema dual (Yoshikawa *et al.*, 2007):

$$\begin{aligned} \max_{\lambda} \quad & \sum_{i=1}^D \lambda_i - \frac{1}{2} \sum_{i,j=1}^D \lambda_i \lambda_j y_i y_j k(x_i, x) \\ \text{sujeito a} \quad & \sum_{i=1}^D \lambda_i y_i = 0, 0 \leq \lambda_i \leq C, \end{aligned} \quad (2.25)$$

no qual,  $x_i$  é o vetor suportado correspondente ao valor de  $\lambda_i$  diferente de zero e  $C$  é a constante de regularização que decide o grau da classificação dos erros.

Liu *et al.* (2007) propõem a *Cascade Kernel Learning Machine* (CKLM) onde as características dos sinais mioelétricos são extraídas pelo modelo AR e histograma de EMG. Um estágio de redução de dimensionalidade dos vetores de entrada é implementado através da análise de discriminante generalizado (*Generalized Discriminant Analysis*, GDA) enquanto o estágio de classificação utiliza a SVM para a discriminação dos padrões mioelétricos. Os resultados obtidos em uma comparação para dois sujeitos amputados e um saudável (para a discriminação de 8 classes de movimento), com respeito a outros algoritmos de classificação como MLP e KNN, demonstram a superioridade do método

CKLM, apresentando uma alta taxa de reconhecimento na classificação de 93,54% com respeito a 67,34% e 72,21% para os métodos MLP e KNN. Yoshikawa *et al.* (2007) implementaram a estimação contínua de ângulos do deslocamento dos membros da mão, utilizando como estágio de classificação a SVM. Os resultados experimentais para 7 sujeitos saudáveis apresentaram uma alta taxa de reconhecimento na classificação de 90%.

#### 2.6.5.6 – Treinamento *online*

As características dos sinais mioelétricos coletados variam com o tempo, e fazem com que o erro nos sistemas de controle baseados no reconhecimento de padrões se incremente de forma exponencial durante longos períodos de operação. O motivo principal deve-se ao fato de que os padrões de sinais utilizados para o treinamento diferem de forma incrementada dos padrões atuais depois de um período e, conseqüentemente, a exatidão na classificação cai notavelmente. O treinamento *online* requer que o classificador use continuamente novos padrões durante a operação, fazendo com que a taxa do classificador permaneça estável, com os padrões monitorados e avaliados continuamente para atualizar os dados de treinamento. Fakuda *et al.* (2003) utilizaram a entropia como medida para validar os pares de entrada-saída, definida como:

$$E(i) = \sum_{n=1}^N O_n(i) \log O_n(i), \quad (2.26)$$

no qual,  $O(i)$  representam os padrões de saída e  $N$  o número de padrões. O trabalho mostra que, quando a entropia resultante da classificação dos vetores de entrada  $x(i)$  é menor que certo limiar, a confiabilidade dos padrões classificados é alta e os pares  $[x(i), O(i)]$  podem ser adicionados ao conjunto dos dados para o treinamento *online*. Os pesos da rede são então atualizados, baseados no novo conjunto. Se a função de entropia na rede não se decrementa durante as próximas iterações do treinamento *online*, os pesos não poderão ser atualizados para evitar erros durante o treinamento. Isso significa que os pesos são modificados gradualmente e a classificação não se degrada de forma rápida.

## 2.6.6– Fusão de dados em algoritmos mioelétricos

As técnicas de fusão de dados multisensoriais têm encontrado muitas aplicações na indústria e no comércio. A fusão de dados é o processo contínuo de projeção de um modelo melhorado na estimativa de um sistema, através de um conjunto independente de sensores (Gao e Harris, 2002). A integração ou fusão de informação redundante pode aumentar a precisão do sistema, além de melhorar sua confiabilidade na correção de erros e falhas nos sensores. Existem várias técnicas de fusão multi-sensores, dentre dos quais, o filtro de *Kalman* é uma das mais significativas (Diniz, 2008). Para as aplicações em tempo real, o modelo de interesse é o vetor de estado de um processo dinâmico. A combinação da informação a partir dos sensores e a subsequente estimação da variável de estado devem ser implementados em uma forma coerente e consistente com o objetivo de reduzir o grau de incerteza (Gao e Harris, 2002).

O filtro de *Kalman* é um dos algoritmos mais aplicados nas estimações de variáveis de estados e seu objetivo é gerar um algoritmo recursivo linear, com mínimo erro de variância, para estimação ótima das variáveis de estados de um sistema dinâmico linear (Diniz, 2008). O processo do filtro de *Kalman* é considerado como uma formulação de predição-correção, utilizando um modelo linear predefinido do sistema para prever o estado do próximo passo de iteração e adicionando uma componente para atualizar os erros no modelo através das observações atuais do sistema (Diniz, 2008). Considerando um sistema dinâmico linear e  $N$  sensores, a formulação do filtro de *Kalman*, baseada no modelo do espaço-estado é representado por (Diniz, 2008):

$$x(k)=A(k-1)x(k-1)+q(k) \quad (2.27)$$

$$y(k)=C^T(k)x(k)+r(k), \quad (2.28)$$

no qual,  $k$  representa o índice de tempo discreto,  $x(k)$  é o vetor de estado,  $y(k)$  o vetor de medição,  $A(k)$  e  $C(k)$  são os modelos de observação das variáveis de estado de  $N$  sensores respectivamente;  $q(k)$  e  $r(k)$  são processos de ruído gaussiano com médias nulas e matrizes de covariâncias  $Q(k)$  e  $R(k)$ , respectivamente (Luo *et al.*, 2002). O filtro de *Kalman* apresenta duas fases: predição e correção. A fase de predição usa a estimativa a partir do

passo do tempo anterior para gerar uma estimativa do estado no passo atual, dadas as seguintes equações (Diniz, 2008):

$$\hat{x}(k|k-1) = A(k-1)\hat{x}(k-1|k-1) \quad (2.29)$$

$$R_e(k|k-1) = A(k-1)R_e(k-1|k-1)A^T(k-1) + Q(k), \quad (2.30)$$

no qual,  $\hat{x}(k|k-1)$  e  $R_e(k|k-1)$  representam as estimativas da predição a priori da variável de estado e da matriz da covariância no tempo discreto  $k-1$ , respectivamente. Na fase de correção, a estimativa a priori é combinada, com a informação da observação atual para corrigir a estimativa do estado (estimativa a posterior), tendo em conta as seguintes equações (Diniz, 2008):

$$K(k) = R_e(k|k-1)C(k) [C^T(k)R_e(k|k-1)C(k) + R_e(k)]^{-1} \quad (2.31)$$

$$\hat{x}(k|k) = A(k-1)\hat{x}(k-1|k-1) + K(k)[y(k) - C^T(k)\hat{x}(k|k-1)] \quad (2.32)$$

$$R_e(k|k) = [I - K(k)C^T(k)]R_e(k|k-1), \quad (2.33)$$

no qual, o termo  $A(k-1)\hat{x}(k-1|k-1)$  fornece a contribuição da estimação prévia da variável de estado à estimação atual; o termo  $[y(k) - C^T(k)A(k-1)\hat{x}(k-1|k-1)]$  é um termo de correção que consiste na diferença entre o vetor de observação e sua estimativa; o ganho do filtro de  $K(k)$  tem como objetivo, filtrar os erros de estimação e ruído assim que a variável de estado consiga a melhor correção possível, reduzindo o erro quadrático médio (Diniz, 2008).

Os métodos de fusão de dados baseados em filtro de *Kalman* apresentam baixos erros de estimação e fazem uso de informação local fusionada para fornecer, em cada ciclo de iteração, uma melhor estimação (Gao e Harris, 2002). Os altos níveis de amplificação requeridos, dados os baixos níveis do SMES, fazem que o controle mioelétrico seja sensível às mudanças de amplitudes. Isso dificulta o controle de próteses, já que as articulações mecânicas poderiam estar sujeitas a deslocamentos ou velocidades fora da

faixa de operação permitida (Lopez *et al.*, 2009). Durante os processos de medição dos sinais mioelétricos, pode-se gerar ruído de baixa frequência relacionado com a variação da tensão média do SME, chamado artefato de movimento, devido a pequenos deslocamentos dos eletrodos, quando se produz a contração muscular e movimentos dos cabos de captação. Os problemas anteriormente citados poderiam ser solucionados a partir de um processo de estimação e correção através dos algoritmos de fusão de dados.

Silva *et al.* (2003) utilizaram fusão de dados através de sinais mecanomagnéticas para a geração de um controle binário em uma prótese ativa. Uma estratégia de fusão baseada no valor RMS dos sinais segmentadas, adquiridas por sensores acelerômetros foi utilizada em processo de treino e no processo de detecção. Foram obtidos ótimos resultados, com taxa de classificação de 95% e não satisfatórios de 86%, na detecção de padrões mioelétricos relacionados ao processo de extensão e flexão na mão, respectivamente. Lopez *et al.* (2009) apresentam duas estratégias de fusão de dados, utilizando sinais mioelétricos, baseadas na média, dos pesos da variância (*Variance Weighted Average*, VWA) e no filtro de *Kalman* descentralizado (*Decentralized Kalman Filter*, DKF), por meio de arranjo de potenciais redundantes através do SMES. A amplitude de contração muscular é estimada através dos algoritmos e transformada em uma referência angular para efetuar o controle da junta em um robô. Ambos os algoritmos foram testados em vários indivíduos sobre diversas condições, como por exemplo, os eletrodos foram conectados e re-conectados de diferentes formas. Houve introdução de ruído no modelo matemático do robô, para o cálculo da trajetória da junta com falhas. Embora a transformação do sinal a uma coordenada da junta não seja mais exato, quando se compara ao padrão utilizado, as falhas são ignoradas pelo sistema de controle e o sinal de referência da junta não excede os limites de operação estabelecidos, o que demonstra o alto desempenho dos algoritmos.

## **2.7- CONCLUSÕES DO CAPÍTULO**

Os sinais mioelétricos de superfície são formados pela soma dos potenciais de ação individuais, gerados pela descarga irregular das unidades motoras nas fibras musculares. As mesmas contêm informações a partir das quais a intenção de movimento do

usuário pode ser detectada usando eletrodos de superfície. Os indivíduos amputados e com deficiências motoras são capazes de gerar padrões através dos sinais mioelétricos, de forma repetitiva e que variam gradualmente, podendo ser usados para o controle mioelétrico.

Os níveis da atividade dos músculos em contrações estáticas e dinâmicas é o fator mais importante a se levar em conta no desenvolvimento dos algoritmos mioelétricos. Porém, o conjunto de características no domínio do tempo, que representa a energia nos SMEs, com características no domínio espectral, que representa o espectro de potência, poderia propiciar melhor desempenho para os algoritmos mioelétricos. Este é justamente o objetivo da primeira proposta do algoritmo de trabalho de tese de doutorado, onde se mesclam os métodos de mínimo quadrado recursivo (domínio espectral) com o histograma de EMG (domínio temporal) no estágio de extração de características, procurando aumentar a exatidão da classificação e a eficiência computacional.

Os movimentos dos membros são gerados a partir da ativação concorrente dos músculos pequenos e grandes. Porém, um aumento do número dos canais mioelétricos trouxe consigo a seleção de outras áreas de coleta dos dados no processo da classificação dos padrões e, por conseguinte, uma melhoria na exatidão, gerando-se padrões mais discriminativos para os sinais de entrada associados a cada movimento. Isto aumenta a geração de informação redundante, assim como as variações dos vetores característicos no espaço original. Isto poderia ser solucionado com a inserção de um estágio de redução de dimensionalidade, como apresenta a primeira proposta do algoritmo.

As técnicas de fusão de dados são frequentemente implementadas onde a informação é redundante e de natureza diversa. Nas aplicações do controle mioelétrico para prótese, as variáveis de interesse são medidas por dois ou mais pares de eletrodos para aumentar a qualidade da informação extraída. A fusão de informação mioelétrica com sensores proprioceptivos contribuiria para reduzir a sensibilidade do controle mioelétrico relativo a falhas nos eletrodos e ocorrência dos artefatos de movimento, conseguindo aumentar o desempenho e robustez no sistema. A segunda proposta de algoritmo propõe uma arquitetura de fusão de dados, onde se procura fazer a correção do deslocamento angular do joelho, a partir de sensores giroscópios com a informação de posição angular,

obtido a partir de estágios de extração e classificação do SMES, visando melhorar os resultados com respeito às técnicas convencionais de extração e classificação de padrões mioelétricos.

### 3- BIOINSTRUMENTAÇÃO E PROTOCOLO EXPERIMENTAL

A Figura 3.1 apresenta um diagrama esquemático da plataforma experimental, composta por um módulo de bioinstrumentação e um software em tempo real para a aquisição dos sinais mioelétricos e sensores proprioceptivos (eletrogoniômetro e giroscópios). O módulo de bioinstrumentação permite adquirir e pré-processar até 4 canais mioelétricos em configuração bipolar e sensores proprioceptivos. Embora o sistema tenha sido concebido para seu funcionamento em modo autônomo, o mesmo pode trabalhar como parte da arquitetura de controle e instrumentação do projeto da prótese da perna em desenvolvimento (Delis *et al.*, 2008; Delis *et al.*, 2009). O módulo de software permite: a aquisição dos sinais em tempo real por meio do módulo de bioinstrumentação; a visualização dos dados e o emprego de ferramentas para o processamento de sinais.

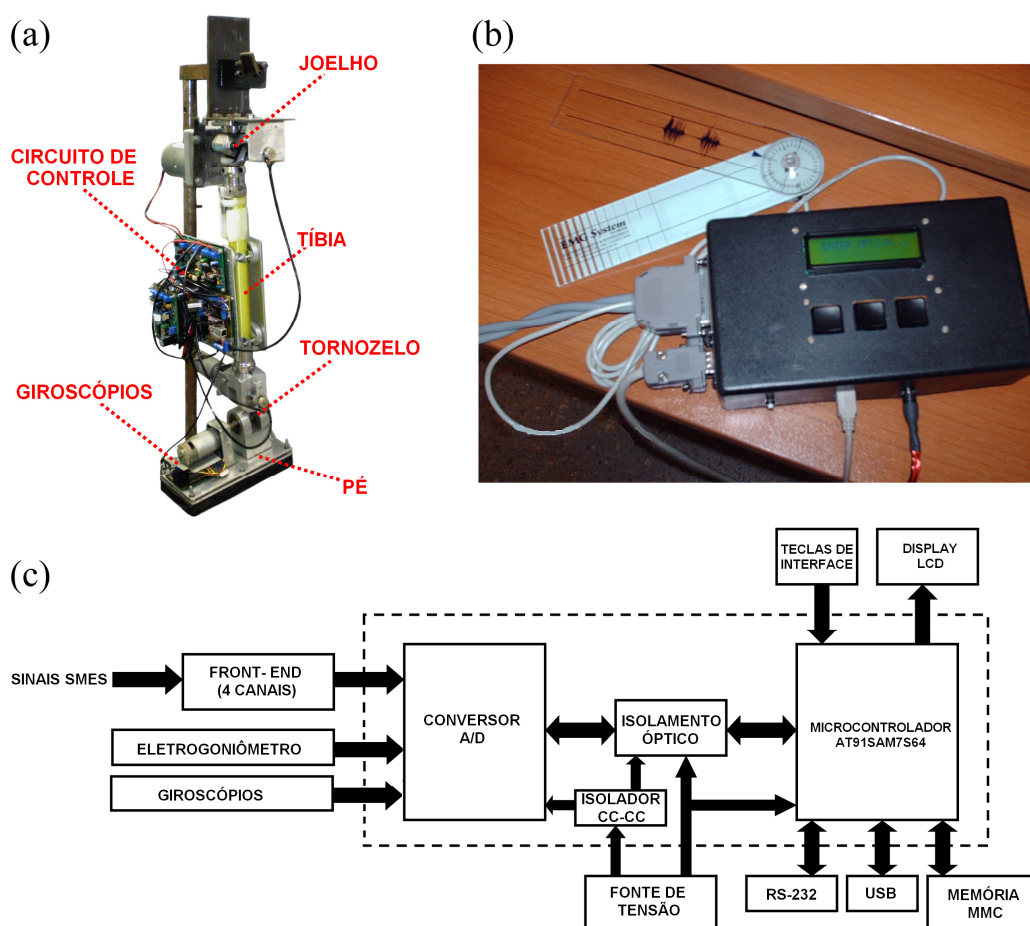


Figura 3.1 - (a) Protótipo de prótese; (b) sistema de instrumentação com sensores proprioceptivos; (c) diagrama esquemático do sistema de instrumentação.



### 3.1 – ESTRUTURA DO BLOCO DE BIOINSTRUMENTAÇÃO PARA SINAIS MIOELÉTRICOS

A aquisição criteriosa dos sinais mioelétricos é um pré-requisito na implementação dos algoritmos mioelétricos para a estimação de movimento (Delis *et al*, 2008). Em particular, o projeto SENIAM definiu algumas recomendações com respeito ao uso de amplificadores integrados de baixo ruído e alta impedância de entrada para adquirir os SMES (SENIAM, 2008). O sistema de bioinstrumentação teve em conta as recomendações definidas pelo projeto SENIAM, assim como um aumento no número de canais de entrada dos SMEs e sensores proprioceptivos para garantir um controle mais preciso. Os requisitos quanto à segurança do paciente através do isolamento óptico foram analisados durante a concepção e projeto do sistema.

O módulo de bioinstrumentação é formado por um estágio de aquisição e condicionamento composto por quatro canais do SMES (amplificadores de instrumentação e filtros passa-faixa). Os sinais são adquiridos por meio de eletrodos posicionados em músculos agonistas e antagonistas da perna, relacionados com os movimentos de flexão e extensão do joelho, (Figura 3.2 a e b). A configuração bipolar usada nos amplificadores diferenciais, que possui taxa de rejeição em modo comum maior que 110 dB (amplificadores INA118 de *Burr-Brown Corp. Tucson, AZ/Texas Instruments Inc., Dallas, TX*), atenua significativamente a interferência proveniente da rede elétrica. Um filtro passa-faixa de 20 Hz a 500 Hz é implementado por meio de um filtro passa-baixas e um filtro passa-altas com um estágio de ganho programável a partir de potenciômetros digitais, controlado por um micro-controlador. O micro-controlador é do tipo ARM-SAM764 de alto desempenho do fabricante ATMEL. Os mesmos estão baseados em uma arquitetura de 32 bits RISC com um grupo integrado de periféricos que minimizam o número de componentes externos. Sua programação foi realizada por meio do pacote de ferramentas em linguagem C/C++ *WinArm*. A ferramenta faz uso da interface JTAG e de um compilador para traduzir o código da linguagem de alto nível para a linguagem do ARM-SAM764. O código é posteriormente carregado na memória *Flash* do micro-controlador, para sua posterior execução.

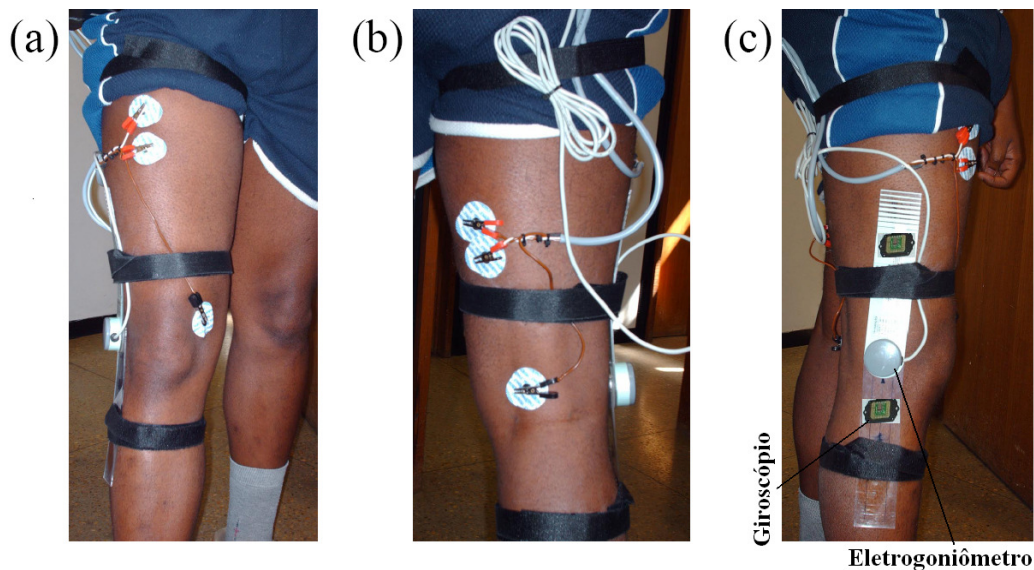


Figura 3.2 - Localização dos eletrodos: (a) músculo agonista; (b) músculo antagonista; (c) sensores eletrogoniômetro e giroscópios.

Para minimizar o consumo de energia e incrementar a imunidade ao ruído, foram utilizados amplificadores operacionais com entrada JFET. Um ganho total de até 20.000 V/V pode ser programado para adequar os níveis do sinal mioelétrico ao bloco de aquisição e condicionamento. Um segundo bloco micro-controlado, com isolamento óptica (conversor CC-CC de *C&D Technologies Inc., Blue Bell, PA*), centraliza todas as funções relacionadas com o processo de conversão analógico-digital, permitindo o controle digital e uma amostragem sincronizada do SMES. Um conversor analógico-digital com interface serial periférica de 13 bits (MCP3304 de *Microchip Technology Inc., Chandler, AZ*), controlado por meio do micro-controlador, permite discriminar pequenos níveis de amplitude com uma resolução de 610  $\mu\text{V}$  (Delis *et al.*, 2008).

O sistema fornece os protocolos de comunicação RS-485, RS-232C e USB conforme ilustrado Figura 3.1. Durante o funcionamento do sistema de bioinstrumentação, visualizam-se os estados dos experimentos durante sua realização por meio de um display LCD. O sensor de eletrogoniometria acoplado ao sistema (eletrogoniômetro da EMG System do Brasil Ltda., São José dos Campos, Brasil) gera um sinal elétrico correspondente à posição angular na faixa de 30 a 240 graus, e dois sensores giroscópios micro-eletromecânicos com condicionamento de sinal (*Analog Devices*) fornecem a informação relacionada com a velocidade angular (Figura 3.2c). Os sensores são

multiplexados no processo de amostragem com o SMES, conforme ilustrado na Figura 3.3 (Delis *et al.*, 2008).

A frequência de amostragem no processo de coleta de dados é de 1744,25 Hz/canal (para a implementação do primeiro protocolo clínico) e 1043,45 Hz/canal (para a implementação do segundo protocolo clínico), a mesma é determinada com base a faixa de frequência máxima do SMES e tendo em conta o número de canais a adquirir (Teorema de Nyquist Delsys, 2003). A implementação dos protocolos experimentais e o processamento dos dados são efetuados de forma *off-line*, como será mostrado posteriormente.




Figura 3.3 - SMES adquirido em músculos agonista e antagonista: canal de eletromiografia #1 (músculo do reto femoral); canal de eletromiografia #2 (músculo semitendinoso); canal de eletrogoniometria (coleta do deslocamento angular no joelho); sensores giroscópios (coleta da velocidade angular) no músculo e na perna.

### 3.1.1 – Implementação do filtro adaptativo

A interferência da rede elétrica tem seus primeiros harmônicos (60 Hz, 120 Hz, 180 Hz, e 240 Hz) na faixa do espectro com maior concentração de energia do SMES. O uso de um filtro *notch* pode, além de minimizar a interferência, distorcer o conteúdo espectral do sinal, e seu uso é recomendado apenas nas situações em que este é essencial (Zhang *et al.*, 1997). Usualmente, a melhor opção consiste em usar um filtro adaptativo. Uma sub-rotina embarcada no núcleo do ARM-SAM764 implementa um filtro adaptativo em tempo real. O filtro mantém um estimador em tempo real da interferência de 60 Hz, e o ruído presente no instante  $t$  pode ser estimado a partir de duas estimativas prévias (Ahlstrom e Tompkins, 1985; Hamilton, 1996), conforme as Equações (3.1) e (3.2):

$$e(t) = N e(t - nT) - e(t - 2nT), \quad (3.1)$$

no qual,  $T$  é o período de amostragem correspondente ao índice  $n$ -ésimo da amostra de entrada e  $N = 2\cos(2\pi \cdot 60 \cdot T)$ . A saída do filtro é gerada subtraindo-se a estimativa do ruído  $e(t)$  a partir do sinal de entrada  $x(t)$ . A expressão apresentada na Equação (3.2) é usada para implementar o filtro (Hamilton, 1996).

$$f(t) = [x(t) - e(t)] - [x(t - nT) - e(t - nT)] \quad (3.2)$$

Se  $f(t) > 0$ , a estimativa corrente do ruído é baixa. Assim, na próxima estimação, incrementa-se pelo fator  $d$  (Ahlstrom e Tompkins, 1985; Hamilton, 1996):

$$e(t + 1) = e(t) + d \quad (3.3)$$

Se  $f(t) < 0$ , a estimativa corrente do ruído é alta e, neste caso, a próxima estimação é decrementada pelo fator  $d$  (Ahlstrom e Tompkins, 1985; Hamilton, 1996):

$$e(t + 1) = e(t) - d \quad (3.4)$$

Se  $f(t)=0$ , a estimativa corrente do ruído é correta e a próxima estimativa seguirá a frequência de 60 Hz (Ahlstrom e Tompkins, 1985; Hamilton, 1996). O fator  $d$  representa uma quantidade cuja escolha é empírica. A mesma é pequena quando comparada com a faixa dinâmica do conversor A/D (Hamilton, 1996). Quando  $d$  é grande, o filtro se adapta mais rapidamente e atenua uma faixa de frequência mais longa. Quando  $d$  é pequeno, o filtro se adapta mais lentamente e atenua uma faixa de frequência mais estreita. A Figura 3.4 ilustra um exemplo de filtragem adaptativa efetuada em um SMES coletado no reto femoral. A mesma ilustra o alto nível de interferência de 60 Hz coletada no SMES associada aos equipamentos de instrumentação e indução eletromagnética no sujeito (Figura 3.4a). Como se apresenta na Figura 3.4b, uma ótima redução da interferência é obtida permitindo reduzir o número de artefatos e falsos positivos durante a estimação do ângulo do joelho.




Figura 3.4 - Filtragem adaptativa implementada em um SMES coletado no músculo reto femoral, contaminado com ruído de 60 Hz. Sinal adquirido no sistema de bioinstrumentação.




Figura 3.5 - Estimação do ângulo realizada pelo algoritmo de extração e classificação de padrões: (a) sem filtragem adaptativa do SMES, (b) com filtragem adaptativa do SMES.

Outro exemplo é ilustrado na Figura 3.5, onde é apresentado o resultado da estimação do ângulo do joelho utilizando os algoritmos mioelétricos propostos neste trabalho, com uma aquisição de sinais de teste adquiridos (durante o caminhar). A Figura 3.5 apresenta a estimação do ângulo do joelho, com a implementação da filtragem adaptativa e sem ele, durante o processo de coleta dos sinais mioelétricos. É possível observar que, em ambos os casos, houve boa conformidade entre o ângulo medido e a estimativa, com base na análise dos sinais mioelétricos (Delis *et al.*, 2009). No entanto, quando se faz a estimação sem filtragem adaptativa, é produzido um pico, que dependendo da duração do mesmo, pode ser imperceptível e filtrado pela inércia do motor do joelho (Ferreira *et al.*, 2005), ou pode provocar um erro na atuação do mesmo.

### 3.2 – MÓDULO DE SOFTWARE PARA COLETA DOS DADOS

Para a implementação do processo de aquisição por meio da plataforma experimental e levando em conta as características que o software deveria apresentar para

um ótimo desempenho, alguns requerimentos foram considerados em sua implementação (De Toledo, 2008):

**Flexibilidade.** A arquitetura do software deve possibilitar as atualizações, dadas as mudanças no protocolo de aquisição e, especialmente, para suportar as alterações no *hardware* de bioinstrumentação (como o aumento do número de canais mioelétricos e sensores proprioceptivos).

**Adaptabilidade.** O software deve ser amplamente configurável, permitindo adaptação em seus parâmetros (número de canais do SMES, sensores proprioceptivos, frequência de amostragem, protocolos de comunicação e duração dos experimentos).

**Interatividade.** A interface visual deve ser fácil, intuitiva e amigável.

**Operação em tempo real.** O software deve operar em tempo real. As funções relacionadas aos processos de aquisição não devem ser interrompidas antes da finalização de algum outro evento.

O software foi implementado em plataforma *Visual C++* e permite a comunicação (*on-line*) com o bloco de instrumentação baseada nas interfaces RS-232C e USB. Por meio de uma interface interativa com o usuário, os parâmetros relacionados ao processo de aquisição (frequência de amostragem, número de canais do SME, sensor de eletrogoniometria e outras variáveis externas) podem ser configurados. Para uma configuração prévia dos parâmetros, assim como para o tempo de duração do experimento, foi estabelecido um protocolo de comunicação entre o software e o bloco de instrumentação (De Toledo, 2008). Considerando que o desenho do gráfico é realizado nos intervalos entre os recebimentos dos dados pelo comunicador (aplicativo relacionado à recepção serial dos dados) havia o risco de perda de dados, pois o aplicativo poderia não conseguir atender à mensagem da serial e esvaziar o seu buffer. Como solução para o problema apresentado, dois métodos diferentes foram implementados para o desenho do gráfico. O método *OnDraw* é obrigatório, visto ser chamado pelas mensagens do próprio sistema operacional nos casos de maximização de janela, alteração de seu tamanho ou

sobreposição, como citado anteriormente. O método *DrawLastScreen* chamado apenas quando uma nova amostra é inserida no canal. A diferença entre os dois métodos é que esse último se restringe a desenhar apenas a nova amostra incluída complementando o gráfico que já havia na tela. Assim o custo de processamento é fixo e independente do número de amostras acumuladas (De Toledo, 2008).

O software permite configurar o *hardware* e realizar os testes para verificar o processo de aquisição, permitindo que os parâmetros estabelecidos, sejam registrados conjuntamente com os sinais adquiridos. O processo de aquisição é dividido em duas fases: processo de treinamento e processo de testes, para a aprendizagem e validação dos algoritmos mioelétricos, respectivamente (De Toledo, 2008). A duração dos experimentos (em segundos) pode ser estabelecida, e ao final de cada processo, os arquivos de treino e testes são exportados para a implementação em modo *off-line* no *Matlab* (*Mathworks, Inc., South Natick, MA*).

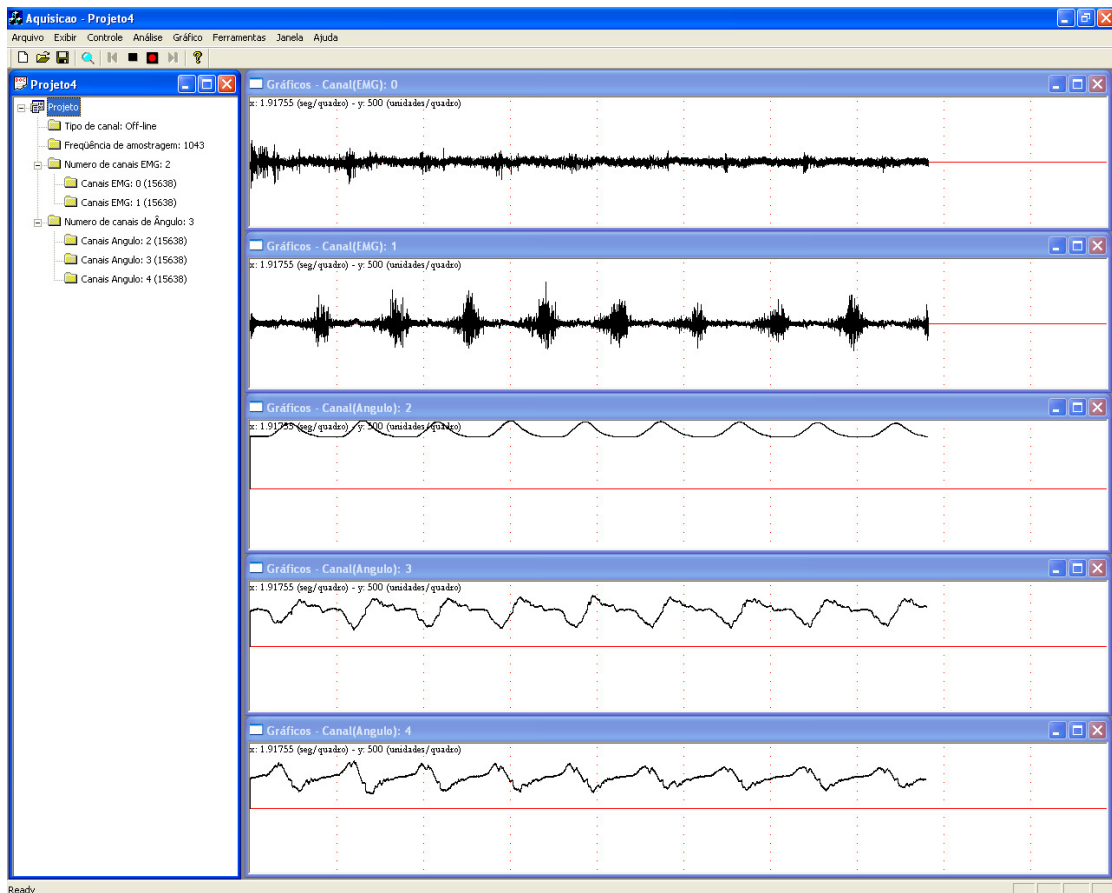


Figura 3.6 - Interface visual do software de tempo real.



### 3.3 – PROTOCOLOS EXPERIMENTAIS

A articulação do joelho é fundamental para um deslocamento normal, além de ter uma função de suporte para o corpo quando o mesmo não se encontra em movimento. O joelho é a articulação intermediária do membro inferior, sendo uma articulação sinovial, com leve degrau de rotação em flexão (Tortora, 2004). Na mesma, articulam-se a rótula com o fêmur e os côndilos femorais com os côndilos tibiais. Os principais movimentos da articulação do joelho consistem na flexão e extensão da perna, embora se observe certo degrau de rotação com o joelho em flexão. A flexão e extensão do joelho são movimentos absolutamente livres, embora a flexão se detenha quando a panturrilha entra em contato com o músculo (Tortora, 2004).

Os estabilizadores dinâmicos são os músculos da região que participam nos movimentos da articulação do joelho: flexão e extensão (Região Posterior e Região Ântero-Lateral). Na flexão, participam os músculos semimembranáceo, semitendíneo e bíceps femoral. Como papéis secundários, participam ainda, os músculos gráceis, cartório e poplíteo. Na extensão, o principal músculo é o quadríceps femoral (reto femoral, vasto lateral, vasto medial e vasto intermédio) (Leis e Trapani, 2000).

As metodologias experimentais que serão apresentadas têm como alvo avaliar o desempenho das propostas de algoritmos. Como primeiro estágio, foram avaliados indivíduos saudáveis para determinar as medições na perna sadia e sua resposta na estimação do ângulo do joelho. A estratégia para o processo de aquisição dos SMEs e da informação dos sensores proprioceptivos teve suporte na plataforma experimental, composta por um módulo de bioinstrumentação e um software em tempo real (Figura 3.7). Os procedimentos foram realizados no laboratório do Grupo de Processamento Digital de Sinais da Universidade de Brasília. O laboratório foi preparado para o posicionamento do voluntário na realização de marchas experimentais, com vistas à coleta de variáveis eletromiográficas e proprioceptivas. O indivíduo deverá ter capacidade de locomoção empregando de uma das pernas saudáveis. Os fatores de exclusão foram: não poderão ter fratura, trauma recente ou apresentar sinais e sintomas de lesões provocadas no segmento da perna a ser analisado. Efetua-se uma familiarização dos voluntários a respeito de todas

as condutas experimentais. Somente após esse estágio, foi fornecido ao voluntário o Termo de Consentimento Livre e Esclarecido, para seu preenchimento.



Figura 3.7 - Colocação do equipamento de bioinstrumentação no indivíduo para a implementação do protocolo experimental.

### **3.3.1 – Implementação do protocolo experimental #1**

O primeiro estudo objetivou avaliar a primeira proposta de algoritmo para a estimação do ângulo do joelho, tendo sido realizado com quatro indivíduos saudáveis (voluntários) utilizando dois canais de SMEs em configuração bipolar, localizados em músculos agonistas e antagonistas relacionados aos movimentos de flexão e extensão da perna. Os eletrodos de superfície são do tipo Ag-AgCl de 10 mm de diâmetro, arranjados em uma configuração bipolar com distância entre os centros dos eletrodos de 3 a 5 mm. Os eletrodos de referência foram posicionados sobre o osso lateral e medial do epicôndilo. O eixo longitudinal dos eletrodos (que passa através de ambas as superfícies de detecção) é alinhado paralelo à longitude das fibras musculares (SENIAM, 2008). O sensor eletrogoniômetro posiciona-se entre a perna e o músculo, no lado externo (os mesmos utilizados para os sensores do SME) para registrar o deslocamento angular do joelho (Figura 3.8). A frequência de amostragem no processo de coleta dos dados utilizado pelo sistema de bioinstrumentação é de 1744,25 Hz/canal. É importante ressaltar que antes da

realização do experimento precisa-se encontrar a zona ótima de estudo para cada indivíduo e, por isso, vários testes de coleta de dados foram realizados, procurando detectar amplitudes consideráveis do sinal mioelétrico na zona de estudo. A Tabela 3.1 apresenta algumas das características de estudos dos quatro voluntários.




Figura 3.8 - Zonas de estudo utilizadas durante o protocolo experimental #1.

Tabela 3.1 - Características de estudo para os sujeitos correspondentes ao protocolo experimental #1.

Sujeitos	Idade	Músculos agonistas e antagonistas	Ganho do <i>Front End</i>
Sujeito A	39 anos	Reto femoral e Semitendinoso	3030
Sujeito B	22 anos	Vasto intermédio e Semitendinoso	6060
Sujeito C	24 anos	Vasto lateral e Semitendinoso	6060
Sujeito D	27 anos	Reto femoral e Semitendinoso	6060

O protocolo experimental foi implementando tendo em conta os seguintes passos:

a) Foi solicitado ao participante para ficar de pé no momento em que é colocado o módulo de bioinstrumentação e seus acessórios (sensores de SMEs e eletrogoniômetro). Foram higienizados com gel (para reduzir a resistência de contato entre a pele e os eletrodos), as possíveis zonas relacionadas com os músculos agonistas e antagonistas onde poderiam ser posicionados os sensores do SMES. Em alguns casos, foi realizada a raspagem do pêlo com lâmina descartável para depilação. Em seguida, os eletrodos foram fixados à pele em configuração bipolar para adquirir os sinais mioelétricos de superfície próximo a: músculos do quadríceps femoral (músculos do reto femoral, vasto lateral, vasto medial e vasto intermédio); e músculos do bíceps femoral, semimembráceo e semitendíneo. Na mesma posição onde o paciente se encontrava de pé, o mesmo que efetuou movimentos de flexão e extensão em forma de marcha com o objetivo de identificar níveis de contração musculares razoáveis a partir dos SMEs. O

módulo de bioinstrumentação transmite as informações relacionadas com os SMEs e as variáveis proprioceptivas ao computador. O pesquisador responsável avaliou com base na qualidade do SMES obtidos na tela do computador se os músculos agonistas e antagonistas escolhidos poderiam contribuir na realização do experimento. Terminada a identificação da zona muscular ótima para os experimentos, foi solicitado ao participante sentar numa cadeira regulável e manter boa postura com os joelhos estendidos, tratando de manter uma postura de relaxamento durante aproximadamente 5 minutos, de forma a evitar os processos de fadiga.

**b)** Terminado o estágio de relaxamento, o participante efetuou uma caminhada em uma direção, com uma velocidade constante de marcha e um tempo aproximado de 10 segundos, durante o qual, as informações coletadas do indivíduo foram registradas na tela do computador para o processo de treinamento dos algoritmos. Terminado este tempo, o pesquisador responsável indica a finalização do experimento e o participante descansara novamente por 5 minutos. Logo após, é realizada a mesma seqüência para o mesmo indivíduo com a mesma velocidade de marcha do experimento anterior, para o processo de validação dos algoritmos. Terminado este processo, a coleta de dados para o participante finaliza. Um novo processo experimental de coleta de dados para outro participante será iniciado desde o primeiro estágio.

Para cada indivíduo, realizou-se um total de 10 medições, com o objetivo de registrar a suficiente variabilidade de passo durante a caminhada. Cada processo de medição foi composto por duas coletas de dados do SME e ângulo, com duração de 10 segundos. Uma das coletas foi utilizada para o processo de treinamento dos algoritmos e outra, para o processo de validação. As medições para cada indivíduo foram efetuadas quatro vezes por dia (durante cinco dias de estudo). Entre cada medição, se estabeleceu um tempo de repouso de, aproximadamente, 5 minutos, para evitar o processo de fadiga. Em cada processo de medição, cada indivíduo efetuou uma caminhada à velocidade de deslocamento constante durante 10 segundos. A informação fornecida pela medida do eletrogoniômetro nesta velocidade é utilizada no processo de treino das redes neurais dos algoritmos mioelétricos. No entanto, em cada uma das medições, a velocidade de deslocamento foi alterada, com o propósito de avaliar a estimação do ângulo pelos

algoritmos a diferentes velocidades de marcha. Foram coletadas um total de 80 conjuntos de dados eletromiográficos, 40 para treinamento e 40 para validação. A Figura 3.9 apresenta coletas de dados realizadas para cada um dos quatro voluntários, nos quais foi realizado o protocolo experimental. O sujeito c (Tabela 3.1) apresentou pequenas variações de amplitude no ângulo de deslocamento, dada a lenta velocidade de marcha efetuada.

### **3.3.2 – Implementação do protocolo experimental #2**

O segundo estudo objetivou avaliar a segunda proposta de algoritmo para a estimação do ângulo do joelho, utilizando sensores proprioceptivos além do SMES. Foi realizado um protocolo experimental (registro no Comitê de Ética em Pesquisa 079/09) em doze indivíduos saudáveis voluntários, com autorização via Termo de Consentimento, ver Apêndice C. Utilizaram-se dois canais de SMEs com eletrodos em configuração bipolar dispostos em músculos agonistas e antagonistas relacionados aos movimentos de flexão e extensão da perna. A escolha do número de indivíduos baseou-se em uma média, utilizada na coleta de informações (9 homens e três mulheres com idades entre 23 – 57 anos), para a avaliação de algoritmos mioelétricos (Huang *et al.*, 2005; Yoshikawa *et al.*, 2007; Nazarpour *et al.*, 2007; Oskoei e Hu, 2008). Os eletrodos de superfície são do tipo Ag/AgCl de 10 mm de diâmetro arranjados em configuração bipolar com distância entre os centros dos eletrodos de 2,5 a 3 mm, sendo que os eletrodos de referência foram localizados sobre o osso lateral e medial do epicôndilo. O eixo longitudinal dos eletrodos (que passa através de ambas as superfícies de detecção) é alinhado paralelo à longitude das fibras musculares (SENIAM, 2008). O sensor eletrogoniômetro se posiciona entre a perna e o músculo no lado externo (os mesmo utilizados para os sensores do SMES). Da mesma forma, posicionam-se os sensores giroscópios entre a perna e o músculo para registrar a velocidade angular. A diferença entre os sinais medidos pelos sensores giroscópios fornece a informação sobre a velocidade angular no deslocamento do joelho. A frequência de amostragem no processo de coleta dos dados utilizado pelo o sistema de bioinstrumentação é de 1043,45 Hz/canal.

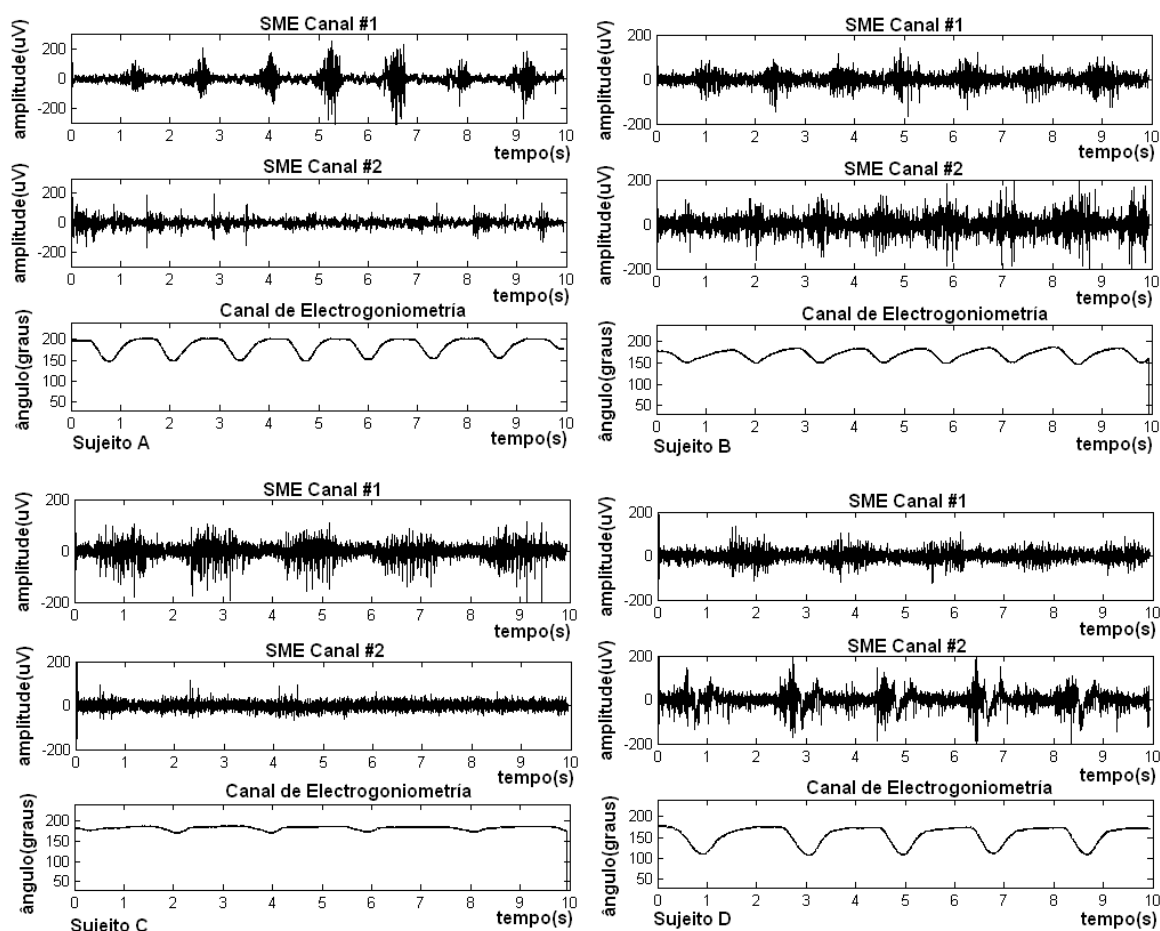


Figura 3.9 - Exemplo de registros dos SMEs e ângulo em cada um dos quatro voluntários; A, B, C e D.

Como no primeiro protocolo, vários testes foram implementados para a detecção da zona ótima de estudo para cada indivíduo. O Apêndice A apresenta as zonas de estudo para músculos agonistas e antagonistas utilizadas na implementação do protocolo, para os doze indivíduos. A Tabela 3.2 apresenta algumas das características de estudo dos doze voluntários.

Tabela 3.2 - Características de estudo para os sujeitos correspondente ao protocolo experimental #2.

Sujeitos	Idade	Músculos agonistas e antagonistas
Sujeito #1	40 anos	Vasto intermédio e Semitendinoso
Sujeito #2	31 anos	Vasto lateral e Semitendinoso
Sujeito #3	28 anos	Vasto lateral e Semitendinoso
Sujeito #4	34 anos	Vasto intermédio e Semitendinoso
Sujeito #5	24 anos	Vasto lateral e Semitendinoso
Sujeito #6	31 anos	Vasto intermédio e Semitendinoso
Sujeito #7	23 anos	Vasto intermédio e Semitendinoso
Sujeito #8	29 anos	Vasto Medial e Semitendinoso
Sujeito #9	57 anos	Vasto intermédio e Semitendinoso
Sujeito #10	56 anos	Vasto intermédio e Semitendinoso
Sujeito #11	26 anos	Vasto Lateral e Semitendinoso
Sujeito #12	57 anos	Vasto intermédio e Semitendinoso

A sequência de passos para a implementação do protocolo experimental diferenciou-se do anterior, em relação à duração da marcha no passo b, sendo esta realizada em 15 segundos. Neste protocolo experimental, para cada indivíduo, foi realizado um total de 10 medições. Cada processo de medição era composto por duas coletas de dados do SME, informação do ângulo de deslocamento e informação de velocidade angular, com duração de 15 segundos. Uma das coletas foi utilizada para o processo de treinamento dos algoritmos a outra para o processo de validação, respectivamente. As medições para cada indivíduo foram efetuadas quatro vezes por dia (durante cinco dias de estudo). Entre cada medição, se estabeleceu-se um tempo de repouso de aproximadamente 5 minutos. Para cada processo de medição, cada indivíduo foi solicitado efetuou uma caminhada à velocidade de deslocamento constante durante 15 segundos. A informação fornecida pela medida do eletrogoniômetro nesta velocidade é utilizada no processo de treino das redes neurais dos algoritmos mioelétricos. No entanto, em cada uma das medições, a velocidade de deslocamento foi alterado com o propósito de avaliar a estimação do ângulo pelos algoritmos a diferentes velocidades de marcha. Foi avaliado um total de 240 conjuntos de dados eletromiográficos, 120 para treinamento e 120 para validação. O Apêndice B apresenta uma das coletas de dados realizada para os doze voluntários nos quais foi realizado o protocolo experimental.

### 3.4 – CONCLUSÃO DO CAPÍTULO

O sistema de bioinstrumentação desenvolvido permitiu a obtenção do SMES com ótima qualidade e mínima contaminação por interferência da rede elétrica devido ao processamento. O sistema é caracterizado por:

1. Quatro canais do SMES, um sensor de eletrogoniometria e dois sensores giroscópios.
2. Amplificadores com CMRR > 110 dB.
3. Filtro passa-faixa de 20-500 Hz com ganho programável.
4. Conversor A/D de 13 bits com interface serial periférica.
5. Resolução de 610  $\mu$ V.
6. Filtro adaptativo para o cancelamento da interferência de 60 Hz.

A filtragem adaptativa eleva a relação sinal-ruído, garantindo significativa redução da taxa de erro de classificação no processo de estimação dos padrões mioelétricos, assim como de falsos positivos e negativos, mesmo em ambientes com altos níveis de ruído proveniente da rede elétrica. O sistema permite a expansão do número de canais mioelétricos e sensores proprioceptivos, visando a implementação de experimentos multisensoriais. O sistema apresenta bom potencial para sua inserção no desenvolvimento na prótese de perna.

A preparação do indivíduo para efetuar a coleta dos sinais mioelétricos e proprioceptivos tem como objetivo maximizar a eficiência, a confiabilidade e qualidade no processo de estimação do ângulo do joelho, por meio dos algoritmos mioelétricos. A observação das condições da pele, anatomia muscular, faixa de movimento muscular e testes de coletas dos SMEs são aspectos a se ter presentes no protocolo experimental e sua implementação. As recomendações do protocolo do SENIAM foram seguidas no uso e posicionamento dos eletrodos, com a utilização de Ag-AgCl de 10 mm de diâmetro, arranjos em uma configuração bipolar com distância entre os centros de 2,5 a 5 mm, sendo que o eixo longitudinal através de ambas as superfícies de detecção este alinhado de forma paralelo à longitude das fibras musculares.



A implementação dos protocolos experimentais possibilitou avaliar se os sinais mioelétricos e sensores proprioceptivos podem ser usados para prever o deslocamento do ângulo do joelho, durante movimentos dinâmicos de flexão e extensão em várias velocidades de marcha. Neste primeiro estágio da implementação dos protocolos clínicos em indivíduos saudáveis, não se objetivou, os testes com fadiga. Isto se deve aos protocolos avaliarem a possibilidade da predição do ângulo do joelho a partir das informações coletadas, seguindo requerimentos estabelecidos (SENIAM, 2008). Nos testes de fadiga, os padrões dos sinais empregados na realização do treinamento diferem dos padrões correntes depois de um período, e conseqüentemente, a exatidão na classificação diminui notavelmente.

## 4- ALGORITMOS MIOELÉTRICOS DE ESTIMAÇÃO CONTÍNUA

Para efetuar o deslocamento do joelho a partir de uma prótese robótica de perna (Ferreira *et al.*, 2005), são necessários comandos provenientes de um controlador mioelétrico formado pelos algoritmos de extração–classificação de padrões e um bloco eletrônico de controle. A função principal do algoritmo mioelétrico é extrair características significativas a partir da intenção de movimento do sujeito e efetuar uma estimação do ângulo para o movimento da junta.

### 4.1 – PRIMEIRA PROPOSTA DE ALGORITMO PARA ESTIMAÇÃO DO ÂNGULO DO JOELHO UTILIZANDO SINAIS MIOELÉTRICOS

Para implementar o processo anteriormente descrito, propõe-se um algoritmo para reconhecimentos de padrões mioelétricos baseado em redes neurais artificiais. O algoritmo mioelétrico é composto por três estágios, a saber:

1. **Extração de características:** são extraídas características significativas do SME que podem conter informação proveniente dos movimentos de flexão e extensão da perna. Utilizam-se métodos no domínio espectral e do tempo que permitem aumentar a robustez do algoritmo (Mínimos Quadrados Recursivos e Histograma).
2. **Projeção de características:** permite uma representação bidimensional do espaço dos vetores de entrada, quando se precisa aumentar o número de sensores, com vistas a incrementar a exatidão do sistema. Também melhora a classificação relativa à redução de informação redundante e de ruído nos vetores entrada. Isso é realizado por meio das redes de mapas auto-organizáveis (SOM).
3. **Classificação dos padrões mioelétricos:** utiliza-se uma rede neural perceptron multicamada que, a partir dos vetores dimensionais de saída da rede SOM, permite o reconhecimento dos movimentos de flexão e extensão da perna.

A Figura 4.1 apresenta um diagrama geral de todo o processo relacionado ao algoritmo mioelétrico. Os estágios que integram o mesmo serão detalhados a seguir.




Figura 4.1- Diagrama geral de blocos do algoritmo mioelétrico.

#### 4.1.1 – Extração de características

Dada a natureza estocástica do sinal mioelétrico, o mesmo pode ser considerado como uma série temporal, sendo modelado como uma combinação linear de seus valores passados e presentes (Reaz *et al.*, 2006). O modelo auto-regressivo é uma estrutura conveniente para a representação desse tipo de sinal, especialmente quando a velocidade computacional e o tempo de resposta são importantes, sendo este o caso da classificação de padrões mioelétricos. Os parâmetros (coeficientes obtidos) contêm informação dos padrões mioelétricos e, por conseguinte, sobre o modo da contração muscular. Para diferentes modos de contração, diferentes coeficientes são associados.

Para a obtenção dos coeficientes, é utilizado o método dos mínimos quadrados recursivos, com fator de esquecimento (Ljung, 1987; Vaseghi, 2000). Este método baseia-se no fato de que as informações de maior importância são aquelas mais próximas à amostra considerada atualmente no ciclo de iteração. O filtro RLS é uma versão atualizada, em tempo de filtragem adaptativo, do filtro *Wiener* (Vaseghi, 2000). Para sinais estacionários, o método RLS converge para coeficientes ótimos, assim como o filtro *Wiener*. Para sinais não estacionários, que é o caso presente, ele segue as variações em tempo do processo, conforme ilustrado na Figura 4.2. De forma geral, o método RLS apresenta uma rápida taxa de convergência para a obtenção dos coeficientes ótimos. Os parâmetros calculados recursivamente (Ljung, 1987; Vaseghi, 2000) são apresentados nas seguintes equações:

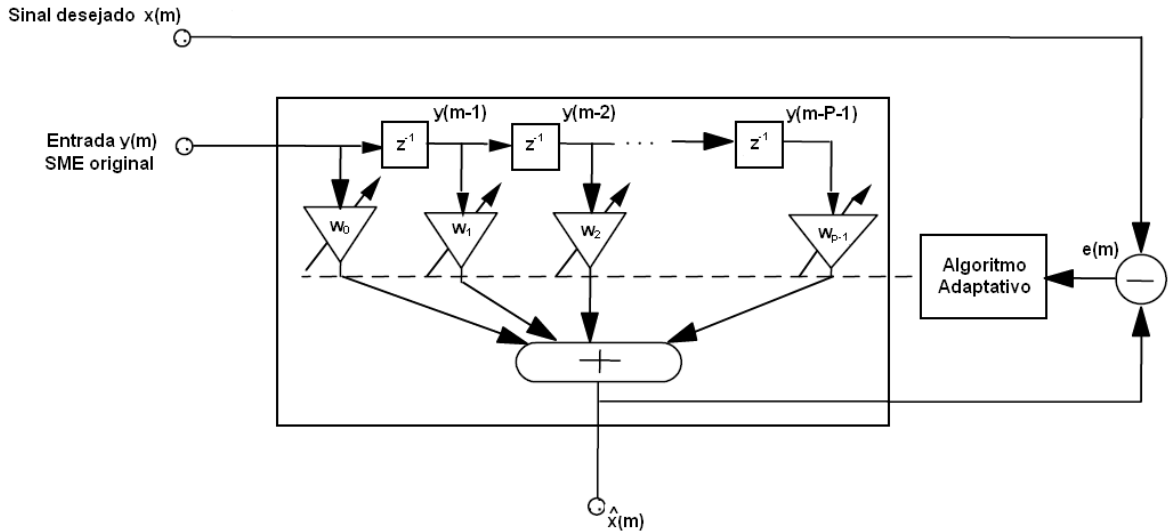


Figura 4.2 - Esquema do filtro adaptativo RLS.

$$\text{Inicializar: } P_k = \text{matriz identidade}, \hat{\eta}_k = 0 \quad (4.1)$$

$$\hat{\eta}_k = \hat{\eta}_{k-1} + L_k [y_k - \varphi_k^T \hat{\eta}_{k-1}] \quad (4.2)$$

$$P_k = \left[ P_{k-1} - \frac{P_{k-1} \varphi_k \varphi_k^T P_{k-1}}{\lambda_k + \varphi_k^T P_{k-1} \varphi_k} \right] \frac{1}{\lambda_k} \quad (4.3)$$

$$L_k = \frac{P_{k-1} \varphi_k}{\lambda_k + \varphi_k^T P_{k-1} \varphi_k},$$

no qual,  $\hat{\eta}_k$  são os vetores de coeficientes que são estimados no tempo discreto  $k$ ;  $\varphi_k$  são os vetores regressivos,  $P_k$  a matriz de correlação inversa e  $L_k$  o vetor de ganho do filtro. O fator de esquecimento  $\lambda_k$  controla a velocidade de resposta do sistema. Se este apresenta o valor 1, o sistema não responde às variações no tempo. Se for menor que 1, responde às variações do sinal e sua velocidade de resposta aumenta a medida em que o fator se reduz. Isto equivale a uma ponderação exponencial com número de amostras dado por (Ljung, 1987; Vaseghi, 2000):

$$N = \frac{1}{(1 - \lambda_k)} \quad (4.4)$$

O processo de adaptação está baseado na minimização do erro quadrático médio (do inglês, *Mean Squared Error*, MSE) definido como:

$$E[e^2(m)] = E\{[x(m) - \eta^T(m)y(m)]^2\} \quad (4.5)$$

no qual,  $y(m)$  e  $x(m)$  denotam os sinais de entrada e saída desejados do filtro RLS, respectivamente. Os coeficientes que são estimados no tempo discreto  $k$  podem ser interpretados como características do SME dentro do intervalo de tempo determinado pelo fator de esquecimento e, portanto, como uma forma de determinar o deslocamento angular que o sujeito deseja impor à prótese (Ferreira *et al.*, 2005). Baseados no critério de *Akaike* (Ljung, 1987), que propõe minimizar a entropia ou a distância de informação entre o modelo e o sistema real, verifica-se que um modelo auto-regressivo de quarta a sexta ordem é o suficientemente eficiente para representar o sinal como uma série temporal.

Recentes pesquisas (Hargrove *et al.*, 2008) demonstram que uma configuração funcional e eficiente consiste em uma mescla de vetores característicos no domínio do tempo com coeficientes auto-regressivos. Esta configuração apresenta ótimas precisões de classificação, sendo computacionalmente eficiente e fácil de realizar em sistemas embarcados, além de ser mais robusta aos deslocamentos dos eletrodos de superfície. Neste algoritmo, é proposta a combinação do histograma do EMG com vetores auto-regressivos. O histograma de EMG é uma combinação do *Zero Crossings* e da Amplitude de *Willison* (Zardoshti-Kermani *et al.*, 1995), dado que o sinal mioelétrico em um processo de contração alcança níveis relativamente altos em relação à linha base. Os vetores obtidos a partir do histograma podem ser uma medida de informação sobre a frequência com a qual o SME alcança múltiplos níveis de amplitude. Sua implementação consiste em estabelecer uma faixa simétrica de amplitude sobre a linha base e subdividir a mesma em níveis, calculando desta forma a frequência com a qual o SME se estabelece dentro dos mesmos.

Os coeficientes auto-regressivos e a janela do histograma (200 amostras, equivalentes a 115 ms, tendo em conta a frequência de amostragem para a implementação do primeiro protocolo clínico) são atualizados para cada nova amostra do SME (Figura 4.3). Isto produz uma sequência semi-redundante de decisões de classes que pode

potencialmente ser utilizada para melhorar o tempo de resposta e a exatidão. Finalmente, no processo de extração, é obtida uma concatenação dos vetores por ambos os métodos para cada canal do SME, os quais se estabelecem como vetores de entrada para a rede SOM.

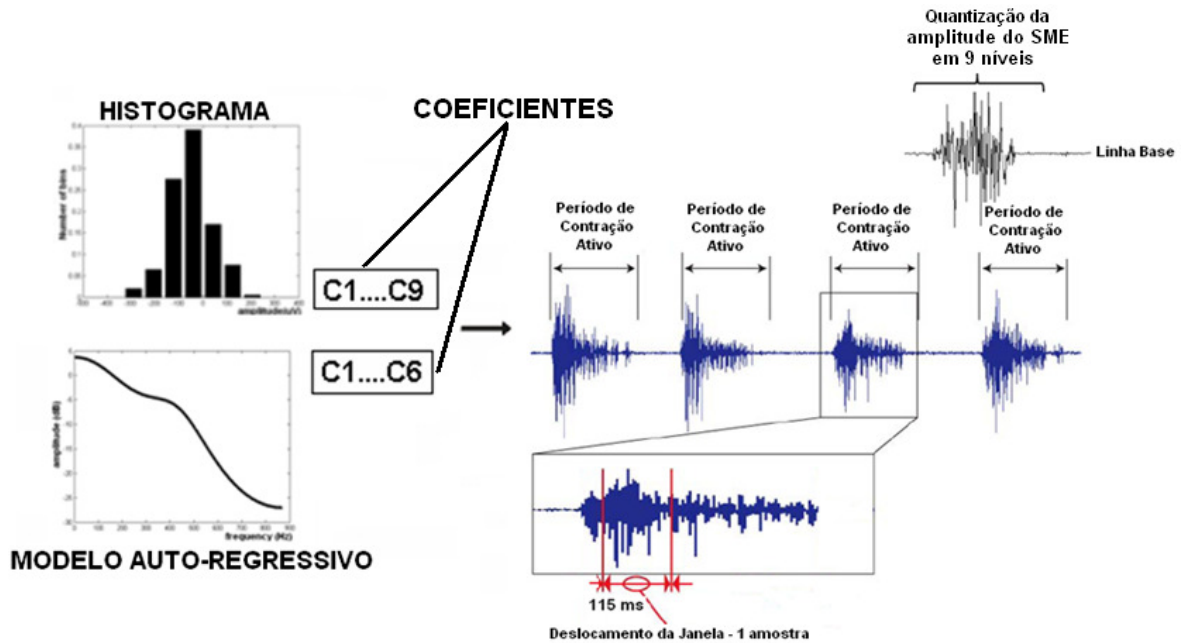


Figura 4.3- Combinação do histograma de EMG e o modelo auto-regressivo.

No processo de extração de características, para o cálculo dos coeficientes do modelo auto-regressivo, foi utilizado um fator de ordem seis para o método RLS. Concluiu-se que um valor adequado para o fator de esquecimento ( $\lambda_k$ ) que reduz a variância dos parâmetros estimados é 0,995, que equivale (dada a Equação 3.8) a 200 amostras (115 ms de duração de janela de dados) no ciclo atual de iteração do algoritmo RLS. Como resultado, um vetor de seis componentes para cada amostra de entrada é obtido. Para a implementação do histograma, durante o processo de treinamento, uma faixa simétrica em relação à linha base do registro do SME é estabelecida e a mesma é subdividida em 9 níveis. A faixa corresponde ao intervalo no qual se agrupam as amostras do sinal e representa uma medida de informação sobre a frequência com a qual o sinal alcança múltiplos níveis de amplitude. O intervalo obtido é o mesmo utilizado durante o processo de validação. Finalmente, para cada amostra de entrada do processo de extração por cada canal do SME, obtém-se um vetor concatenado de 15 componentes correspondentes ao algoritmo RLS e ao histograma, respectivamente (Figura 4.6).

#### 4.1.2 – Projeção de características

O estágio anterior reduz a dimensão dos dados a quinze (nove níveis de frequência do histograma e seis coeficientes auto-regressivos). Os mapas auto-organizáveis podem ser vistos como uma extensão do algoritmo *K-Means* (Huang *et al.*, 2005), onde os protótipos dos agrupamentos estão sujeitos a uma constante de vizinhança que preserva a ordem topológica do espaço de entrada (vetores obtidos a partir do processo de extração de características). Então, os centros dos *clusters*, denominados unidades ou neurônios, são organizados de acordo com uma estrutura de reticulado para formar um mapa. A rede SOM apresenta como propriedades (Haykin, 1999; Kohonen, 2001):

- Ao final do treinamento, os vetores sinápticos formam uma boa codificação do espaço de entrada (Quantização vetorial).
- A posição dos neurônios no mapa representa regiões do espaço de entrada (Ordenamento topológico).
- As variações de densidade no posicionamento dos neurônios refletem variações de densidade no espaço de entrada (Preservação de densidades).
- O mapa representa a melhor projeção possível dos dados na dimensão disponível (Seleção de características).

Além da vantagem na redução da dimensão do espaço de entrada, o SOM pode eliminar ruído, absorver grandes variações que acontecem nos vetores característicos originais e reduzir o tempo de treinamento da rede supervisionada. O SOM pode encontrar um neurônio vencedor em um mapa de duas dimensões para representar os padrões originais, que possuem elevada dimensão (Figura 4.4).

Para a obtenção do neurônio vencedor de acordo com a regra de aprendizagem do SOM, os seguintes passos devem ser implementados (Haykin, 1999):

**Passo #1:** Escolher valores aleatórios para os vetores dos pesos iniciais  $W_j(0)$ .

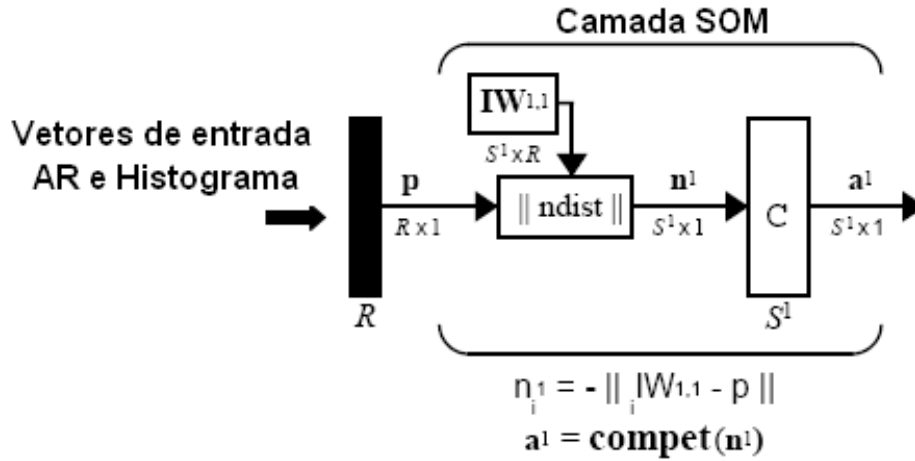


Figura 4.4 - Esquema do mapa auto-organizável.

**Passo #2:** Encontrar o neurônio vencedor,  $y_c$  no passo do tempo  $t$  (*Similarity Matching*), usando o critério de mínima distância euclidiana entre as amostras do vetor de entrada e o vetor dos pesos iniciais:

$$y_c = \operatorname{argmin} \|x(t) - W_j\|, j = 1, 2, \dots, t \quad (4.6)$$

**Passo #3:** Modificar os vetores dos pesos sinápticos de todos os neurônios utilizando a seguinte regra de atualização:

$$W_j(t+1) = W_j(t) + \eta(t) h_{j,y_c}(t) [x(t) - W_j(t)], \quad (4.7)$$

no qual,  $\eta(t)$  é a razão de aprendizagem e  $h_{j,y_c}(t)$  é a função de vizinhança centrada sobre o neurônio vencedor.  $\eta(t)$  e  $h_{j,y_c}(t)$  são dinamicamente modificados durante a fase de aprendizagem para obter resultados ótimos.

**Passo #4:** Voltar ao passo #2 até que nenhuma mudança aconteça no mapa característico.

A razão de aprendizagem pode variar no tempo, de acordo com a seguinte Equação:



$$\eta(t) = \eta_0 \exp\left(-\frac{t}{\tau_1}\right), t = 0, 1, 2, \dots, \quad (4.8)$$

no qual,  $\tau_1$  é a constante do tempo da taxa de aprendizagem. Assume-se ainda, que a função de vizinhança topológica varia no tempo, de acordo com a seguinte Equação:

$$h_{j,y_c}(t) = \exp\left(-\frac{d_{j,y_c}^2}{2\sigma^2(t)}\right), \quad (4.9)$$

no qual,  $d_{j,y_c}$  é a distancia lateral (Haykin, 1999) entre o neurônio vencedor  $y_c$  e o neurônio excitado  $j$  no espaço de saída de duas dimensões, e  $\sigma(t)$  é definido como:

$$\sigma(t) = \sigma_0 \exp\left(-\frac{t}{\tau_2}\right), \quad (4.10)$$

onde  $\tau_2$  é outra constante de tempo da rede SOM. Quando  $t$  é incrementado, o fator  $\sigma(t)$  é decrementado em uma razão exponencial e a vizinhança topológica se reduz proporcionalmente. Cada canal do SME apresenta seus vetores característicos na entrada do SOM e a saída é uma coordenada de duas dimensões, em uma rede topológica com eixos  $x$  e  $y$  que constitui a entrada da rede supervisionada para a classificação dos padrões mioelétricos.

Depois de obter, para cada canal do SME, um vetor característico de 15 componentes, cada grupo é passado por uma rede SOM. Os dois mapas SOM de duas dimensões associados a cada canal são arranjados em uma rede topológica com uma matriz de  $[10 \times 10]$ , com 100 neurônios (sua escolha foi baseada em testes) em sua estrutura de interconexão. O tamanho da função de vizinhança inicial  $h_{j,y_c}(t)$  é de 10, a taxa de aprendizagem inicial  $\eta_0$  é 0,9 e as constantes de tempos  $\tau_1$  e  $\tau_2$  são 1431 e 1000 iterações, respectivamente (Haykin, 1999). A função de vizinhança inicialmente agrupa todos os neurônios na rede centrada ao redor do neurônio vencedor e, posteriormente, a mesma vai reduzindo-se com o tempo. Porém, o valor inicial de  $\sigma_0$  é igual ao raio da rede de saída de duas dimensões (5). Para cada vetor de entrada de 15 elementos, um vetor de duas

coordenadas será obtido como saída da rede SOM e utilizado como entrada na rede neural perceptron multicamada (Figura 4.6). Para o processo de treino da rede SOM, os vetores de coeficientes auto-regressivos e histograma são utilizados para configurar a estrutura do mapa topológico e configurar os pesos de cada neurônio. O mesmo conjunto de vetores de treinamento é utilizado na rede SOM, treinada para gerar os vetores dimensionais a serem utilizados como entrada para o processo de treinamento da rede neural perceptron multicamada.

#### 4.1.3 – Classificação dos padrões mioelétricos

O processo de discriminação dos padrões mioelétricos relacionados aos movimentos de flexão e extensão do joelho é implementado por uma rede neural do tipo perceptron multicamada. Estas têm sido aplicadas com êxito em problemas lineares e não-lineares e, frequentemente, nas áreas de reconhecimento de padrões mioelétricos (Hudgins *et al.*, 1993; Reaz *et al.*, 2006; Oskoei e Hu, 2007). De forma geral, a velocidade de treinamento é baixa, especificamente na rede de aprendizagem *Back Propagation*. Mais recentemente, várias ferramentas têm sido desenvolvidas com o objetivo de acelerar a convergência da rede, dentre elas métodos focados em otimizações numéricas padronizadas (gradiente conjugado, *Quasi-Newton* e mínimos quadrados não lineares) (Battiti, 1992; Charalambous, 1992; Kollias e Anastassiou, 1989). Neste trabalho, aplica-se o método de mínimos quadrados não-lineares com *Levenberg-Marquardt*, para treinamento da rede perceptron multicamada (Hagan e Menhaj, 1994).

Para uma rede perceptron multicamada (três camadas), a tarefa da rede é aprender associações entre conjuntos específicos de pares entrada-saída (Figura 4.5)  $\{(p_1, t_1), (p_2, t_2), \dots, (p_q, t_q)\}$ .




Figura 4.5 - Esquema da rede perceptron multicamada para o algoritmo mioelétrico.

Considerando uma função  $V(x)$ :

$$V(x) = \sum_{i=1}^N e_i^2(x) = \sum_{q=1}^Q \sum_{s=1}^{s_2} (t_q(s) - a_q^2(s))^2, \quad (4.11)$$

no qual,  $a_q^2(s)$  é a  $s$ -ésima saída da rede quando a  $q$ -ésima entrada é apresentada,  $(t_q(s) - a_q^2(s))$  é o erro para a  $g$ -ésima entrada e  $x$  é o vetor de todos os pesos da rede. O objetivo é minimizar  $V(x)$  em relação ao vetor parâmetro  $x$ . Aplicando o método *Gauss-Newton* (Battiti, 1992; Hagan e Menhaj, 1994), tem-se:

$$\Delta_x = -[\nabla^2 V(x)]^{-1} \nabla V(x), \quad (4.12)$$

no qual,  $\nabla^2 V(x)$  é a matriz Hessiana e  $\nabla V(x)$  é o gradiente. Pode ser demonstrado que se  $V(x)$  é uma soma de funções quadráticas:

$$V(x) = \sum_{i=1}^N e_i^2(x), \quad (4.13)$$

Então:

$$\nabla V(x) = J^T(x) e(x) \quad (4.14)$$

$$\nabla^2 V(x) = J^T(x)J(x) + S(x), \quad (4.15)$$

no qual,  $J(x)$  é a matriz Jacobiana (Hagan e Menhaj, 1994) e:

$$S(x) = \sum_{i=1}^N e_i(x) \nabla^2 e_i(x) \quad (4.16)$$

Para o método *Gauss-Newton*, é assumido que  $S(x) \approx 0$ , o que transforma a Equação (4.12) em:

$$\Delta_x = [J^T(x)J(x)]^{-1} J^T(x)e(x) \quad (4.17)$$

e a adaptação do método *Levenberg-Marquardt* nas características do método *Gauss-Newton* resulta em:

$$\Delta_x = [J^T(x)J(x) + \mu I]^{-1} J^T(x)e(x) \quad (4.18)$$

Para grandes valores de  $\mu$ , a rede se transforma no método *steepest descent* (rede *Back-Propagation*). No entanto, para pequenos valores de  $\mu$ , a rede se transforma no método de *Gauss-Newton* (Hagan e Menhaj, 1994). O aspecto principal na rede neural perceptron multicamada com algoritmo de treinamento do tipo LM é o cálculo da matriz Jacobiana, cuja descrição se encontra em (Hagan e Menhaj, 1994). Nas comparações efetuadas desta rede com outras, os resultados têm mostrado que o LM é muito eficiente quando são treinadas redes com até centenas de pesos. Embora sua complexidade computacional seja alta para cada iteração, isso é compensado pela sua alta eficiência; principalmente, quando se necessita de alta exatidão (Hagan e Menhaj, 1994).

#### 4.1.4 – Esquema geral de funcionamento e configuração dos parâmetros para o algoritmo mioelétrico

As Figuras 4.6 e 4.7 apresentam a estrutura do algoritmo mioelétrico e o esquema geral de funcionamento do processo de coleta, pré-processamento do SMES, extração e classificação dos padrões mioelétricos, respectivamente. Durante o processo de coleta, o SMES e o ângulo de deslocamento são visualizados na tela do computador. Finalizado o mesmo, um arquivo com todas as informações do processo de aquisição é gerado, para seu posterior pós-processamento com as ferramentas do *Matlab* (Figura 4.7).

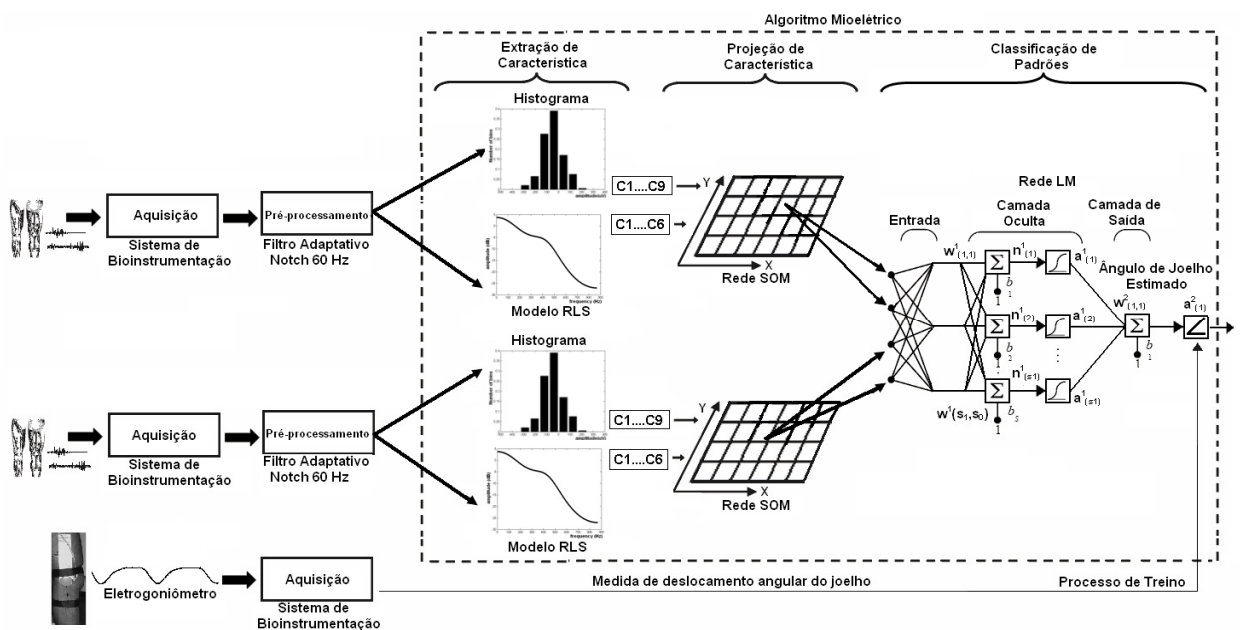


Figura 4.6 - Estrutura do algoritmo mioelétrico.




Figura 4.7 - Esquema geral de funcionamento do processo de coleta do SMES e estimação do ângulo do joelho.

O processo de obtenção da estimativa do ângulo de deslocamento do joelho, neste primeiro estágio da validação dos algoritmos, foi implementado de forma *off-line*. Foram

utilizados dois canais do SMES e um canal de eletrogoniômetro, fazendo uso das ferramentas do *Matlab*. Dois processos caracterizam a estimação do ângulo: o primeiro é um estágio de treinamento, no qual as informações extraídas a partir da coleta de dados servem para treinar os blocos das redes neurais (SOM e perceptron multicamada). O segundo estágio permitirá testar o algoritmo mioelétrico e, a partir da estimativa do ângulo obtido, avaliar o desempenho do algoritmo.

A rede neural perceptron multicamada apresenta quatro entradas (vetores de saída da rede SOM) e duas camadas em sua estrutura. A primeira camada é configurada com seis neurônios que utilizam a função de ativação tangente hiperbólica e uma camada de saída composta por um único neurônio cuja função de ativação é linear. A saída da rede representa a estimativa do ângulo (Figura 4.6). Durante o processo de treinamento, os vetores de saída da rede SOM são utilizados como entrada da rede, e a informação conhecida do deslocamento angular é obtida a partir do eletrogoniômetro com seus valores normalizados. Os valores iniciais dos pesos são os mesmos para as três camadas da rede (valor zero para todos os neurônios). O número máximo de iterações é 50, o critério de parada baseado no erro quadrático médio da saída é  $1e-10$  e a taxa de aprendizagem foi  $\eta = 1$ . A estrutura da rede neural perceptron multicamada, assim como seus parâmetros de aprendizagem, foi determinada com base em testes para se obter o melhor desempenho da mesma (redução do MSE).

#### **4.2 – SEGUNDA PROPOSTA DE ALGORITMOS DE ESTIMAÇÃO DO ÂNGULO DE JOELHO UTILIZANDO FUSÃO DE DADOS ENTRE SINAIS MIOELÉTRICOS E SENSORES PROPRIOCEPTIVOS**

A aplicação da fusão de dados multisensorial tem encontrado amplo uso em diversas áreas (Luo *et al.*, 2002). O alvo do processo de fusão de dados é gerar uma estimativa do modelo de um sistema a partir de um conjunto de fontes de dados independentes. A fusão de dados é o processo contínuo da obtenção de um modelo a partir do domínio de interesse, utilizando dados de diferentes naturezas (Gao e Harris, 2002). A utilização de uma faixa de diversos de sensores permite automaticamente a extração de informação, tendo em conta todas as condições de operação, incrementando o desempenho,

a confiabilidade do sistema e sua autonomia (Dasarathy, 1997; Hall e Llinas, 1997; Luo, 2002, Monaghan *et al.*, 2009). A combinação da informação a partir dos sensores e a subsequente estimação do estado podem ser implementados de uma forma coerente, procurando a redução da incerteza. O filtro de *Kalman* é um estimador de estado amplamente aplicado para, de forma ótima, estimar o estado de um sistema dinâmico linear a partir de observações contaminadas com ruído de distribuição Gaussiana (Manyika e Durrant-Whyte, 1994). O algoritmo usa um modelo predefinido do sistema para prever o estado no próximo passo do tempo (Diniz, 2008).

Nesta seção, são apresentadas três variantes de algoritmos mioelétricos, ambas baseadas em fusão de dados para a estimação de intenção de movimento do ângulo do joelho a partir dos SMEs e sensores proprioceptivos para o controle ativo de uma prótese de perna transfemoral. As três variantes usam um estágio de extração de características, onde métodos no domínio do tempo e no domínio da frequência são combinados. Essa combinação, que representa a informação da energia do sinal (domínio do tempo) unida à informação do espectro de potência (domínio da frequência), fornece boa exatidão de classificação, e é computacionalmente eficiente e robusta aos deslocamentos de eletrodos (Hargrove *et al.*, 2008). Adicionalmente, informação sobre velocidade angular a partir de sensores giroscópios é utilizada para incrementar a exatidão durante a estimação do ângulo.

A primeira variante utiliza um estágio de extração de características, adicional por meio do filtro de *Kalman*, onde a estimativa da velocidade angular (utilizando a informação dos sensores giroscópios), os coeficientes obtidos pelo a análise cepstral e a entropia do SME são fusionados como vetores de entrada a uma rede neural perceptron multicamada para estimar o ângulo do joelho. A segunda variante representa um aperfeiçoamento da proposta anterior, baseado em robustez e redução de artefatos. Nesta, o processo de fusão entre a informação da velocidade angular e a estimativa do ângulo, obtido a partir da rede neural perceptron multicamada, é implementado no processo de correção do filtro de *Kalman*. A saída do filtro é a estimativa do ângulo corrigido no processo de fusão. A terceira variante é uma projeção com as mesmas características que a segunda, com a diferença da incorporação de um teste de compatibilidade entre o processo

de predição e correção do filtro de *Kalman*. Os estágios que integram as variantes de algoritmos serão detalhados a seguir.

Comparações preliminares, utilizando como métodos no processo de extração de características, entre o algoritmo RLS e os coeficientes cepstrais+entropia do SME, apresentarem algumas melhorias quanto ao percentual erro-sinal e o coeficiente de correlação. Por exemplo, avaliações implementadas no sujeito #1 durante o segundo protocolo experimental mostraram resultados do percentual erro-sinal e o coeficiente de correlação para coeficientes cepstrais+entropia do SME de  $5,68\% \pm 1,32\%$  e  $0,85 \pm 0,04$ , respectivamente, em relação ao algoritmo RLS de  $6,73\% \pm 2,47\%$  e  $0,78 \pm 0,13$ , respectivamente. Isto fez com que, nesta segunda proposta de algoritmo baseada em fusão de dados, fosse implementado o estágio de extração de características utilizando coeficientes cepstrais e a entropia do SME.

#### 4.2.1 – Extração de características

A análise cespstral, utilizada como método no domínio da frequência no processo de extração de características, é definida como a transformada de *Fourier* inversa do logaritmo do quadrado da magnitude da Transformada de *Fourier* do sinal (Kang *et al.*, 1995):

$$c(n) = \frac{1}{N} \sum_{k=0}^{N-1} \log(|X(k)|^2) e^{j2\pi kn/N} \quad (4.19)$$

Se todos os pólos da função de transferência, obtidos a partir de um modelo auto-regressivo (Kang *et al.*, 1995), encontram-se dentro do círculo unitário, a função de transferência logarítmica pode ser representada por uma expansão de Laurent e, a partir da Equação (4.19), é possível derivar a seguinte relação recursiva (Kang *et al.*, 1995):

$$\begin{aligned} C_1 &= -a_1 \\ C_i &= -a_i - \sum_{n=1}^{i-1} \left(1 - \frac{n}{i}\right) a_n c_{i-n} \quad l < i \leq p \end{aligned} \quad (4.20)$$



Utilizando a Equação (4.20), os primeiros  $p$  coeficientes cepstrais ( $c_k$ ) podem ser obtidos a partir dos coeficientes ( $a_k$ ) do modelo auto-regressivo de ordem  $p$ . Alguns trabalhos (Kang *et al.*, 1995; Chiou *et al.* 2004) têm reportado que os coeficientes cepstrais derivados do modelo AR apresentam melhor desempenho que os coeficientes auto-regressivos quanto à classificação de padrões mioelétricos. Embora os coeficientes cepstrais sejam derivados a partir dos coeficientes AR, os primeiros não contêm a mesma informação dos coeficientes AR, dado que as operações recursivas provocam mudanças nas características não-lineares (Kang *et al.*, 1995; Campbell, 1997).

Um segundo método no processo de extração de característica é obtido através da entropia do sinal mioelétrico, como o método no domínio do tempo (Ito *et al.*, 2008). O enfoque é baseado na diferença em entropia entre o SME em estado estacionário (estado de repouso) e em estado de movimento. Assumindo que o sinal mioelétrico pode ser aproximado por um processo de distribuição normal com média zero, a entropia do SME pode ser calculada como (Ito *et al.*, 2008):

$$H(\sigma_i) = \frac{1}{2} \log_2(2\pi e \sigma_i^2) \quad (4.21)$$

$$\sigma_i^2 = \frac{1}{N-1} \sum_{n=1}^N x_i(n)^2, \quad (4.22)$$

no qual,  $\sigma_i^2$  representa a variância estimada do sinal mioelétrico a partir de cada eletrodo e  $x_i(n)$  é um vetor que contém  $N$  amostras do SME para cada  $i$ -ésimo eletrodo. Para cada canal do SMES, a entropia é calculada e concatenada com o vetor característico de coeficientes cepstrais.

#### 4.2.2 – Classificação dos padrões mioelétricos

O estágio de classificação de padrões tem como objetivo estimar o ângulo do joelho a partir da concatenação dos vetores característicos dos SMEs (coeficientes cepstrais e entropia) e a estimativa da velocidade angular para a primeira variante de fusão de dados, e a partir de vetores característicos dos SMEs para a segunda e terceira variante

de fusão de dados. Isso é implementado de forma similar ao capítulo 4 usando a rede neural perceptron multicamada. O algoritmo de treinamento LM é uma modificação do método *Gauss-Newton* (Hagan e Mohammad, 1994) que foi desenvolvida para minimizar funções que sejam a soma dos quadrados de outras funções não-lineares; porém, a rede apresenta um excelente desempenho no processo de treinamento, avaliado pelo erro médio quadrático. O algoritmo converge em menos iterações que outros métodos com o qual já foi comparado (Hagan e Mohammad, 1994). A Figura 4.8 apresenta um esquema em blocos dos processos de extração e classificação dos padrões mioelétricos.




Figura 4.8 - Esquema do processo de extração de características e classificação para as variantes de algoritmos baseadas em fusão de dados.

#### 4.2.3 – Filtragem estocástica na medida de velocidade angular e correção na estimativa do ângulo

A informação da velocidade angular a partir dos sensores giroscópios permite incrementar a exatidão da estimativa do ângulo, além de reduzir a estimativa de artefatos. A fusão dos SMEs com sensores proprioceptivos poderia ser usada para a implementação das correções na estimativa do ângulo do deslocamento do joelho, efetuada pelas redes neurais, além de incrementar a exatidão da prótese durante os movimentos de flexão e extensão, fornecendo um controle mioelétrico mais fiável e robusto. O processo de extração de características para estimar a velocidade angular e efetuar o processo de correção da estimativa do ângulo é implementado por meio do filtro de *Kalman*, a partir das variantes de algoritmos que serão descritas a seguir.

#### 4.2.3.1 – Primeira variante de fusão de dados

A Figura 4.9 apresenta um esquema em blocos da primeira variante de algoritmo baseado em fusão de dados. A estimativa da velocidade angular é modelada usando uma formulação de espaço de estados que descreve seu comportamento dinâmico (Vaseghi, 2000), de acordo com o modelo estocástico linear:

$$x(k) = x(k - 1) + n(k) \quad (4.23)$$

$$y(k) = x(k) + v(k), \quad (4.24)$$

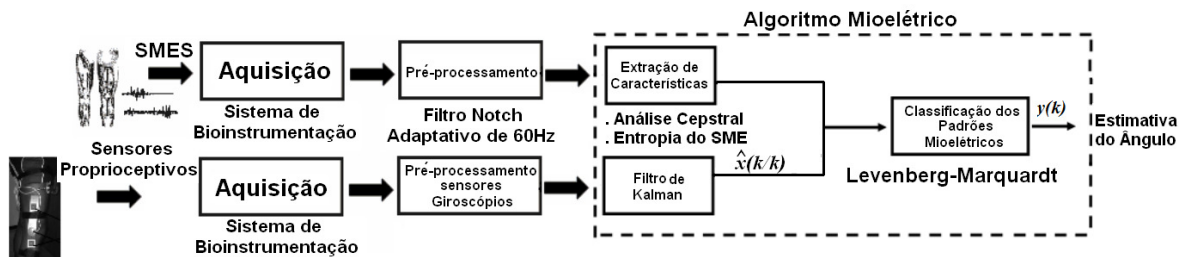


Figura 4.9 - Esquema de funcionamento da primeira variante de algoritmo mioelétrico.

no qual,  $x(k)$  é a velocidade angular do joelho;  $n(k) \sim N(0, \varphi(k))$  é o ruído que modela a evolução da velocidade angular do joelho entre dois intervalos de amostras no tempo discreto  $k$ ;  $y(k)$  é a medida de velocidade angular, obtida a partir da diferença das medidas de velocidade fornecidas pelos sensores giroscópios no músculo e na perna, respectivamente;  $v(k)$  é o ruído da medição. É assumido que  $n(k)$  e  $v(k)$  apresentam média zero, são não-correlacionados com distribuição Gaussiana e variâncias  $q^2$  e  $r^2$ , respectivamente. Quando o filtro de *Kalman* é aplicado ao modelo, para cada ciclo de iteração no tempo discreto  $k$ , o processo de predição é descrito por meio das seguintes equações:

$$\text{Inicializa } r: q^2 = 4, r^2 = 10, x(1) = 0 \text{ e } P(1) = 0,01$$

$$\hat{x}(k/k-1) = \hat{x}(k-1) \quad (4.25)$$

$$P(k/k-1) = P(k-1) + q^2, \quad (4.26)$$

e o processo de correção é descrito por:

$$G(k) = \frac{P(k/k-1)}{(P(k/k-1) + r^2)} \quad (4.27)$$

$$\hat{x}(k/k) = \hat{x}(k/k-1) + G(k)(y(k) - \hat{x}(k/k-1)) \quad (4.28)$$

$$P(k) = (I - G(k))P(k/k-1), \quad (4.29)$$

no qual,  $G(k)$  é o ganho do filtro de *Kalman*;  $P(k)$  representa a matriz de covariância do erro associado ao processo de estimação;  $\hat{x}(k/k)$  é uma estimativa ótima de  $x(k)$ . Para este problema específico, o filtro de é equivalente a um filtro de primeira ordem passa-baixa com frequência de corte que varia no tempo. A frequência de corte é calculada tendo em conta as variâncias do ruído  $q^2$  e  $r^2$ , respectivamente, assim como a matriz da covariância do erro associada a  $\hat{x}(k/k)$ . O valor de  $\hat{x}(k/k)$  é uma estimativa ótima da média da velocidade angular do joelho para cada ciclo de amostragem no tempo discreto  $k$ . Para cada ciclo de iteração  $k$ , a estimativa da velocidade angular do joelho  $\hat{x}(k/k)$ , os coeficientes obtidos a partir das análises cepstrais e a entropia são fusionados como vetores de entrada à rede perceptron multicamada (Figura 4.9).

#### 4.2.3.2 – Segunda variante de fusão de dados

Durante a concepção da proposta de algoritmo baseado em fusão de dados, outra possível variante analisada foi a de fusionar no processo de correção do filtro de *Kalman*, a medida de velocidade angular e a estimativa do ângulo de saída da rede neural perceptron multicamada. A variante poderia reduzir as perturbações que acontecem no processo de estimação do ângulo a partir da rede neural. Nesta segunda estratégia (Figura 4.10), os vetores obtidos a partir do estágio de extração de características (análise cepstral e a entropia no SME) explicado anteriormente, são usados como entrada a uma rede neural perceptron multicamada para obter a estimativa do ângulo de deslocamento do joelho. A estimativa do ângulo é modelada usando uma formulação do espaço de estado,

descrevendo seu comportamento dinâmico, de acordo com o seguinte modelo estocástico linear:

$$x(k) = x(k - 1) + T u(k) + n(k) \quad (4.30)$$

$$y(k) = x(k) + v(k), \quad (4.31)$$

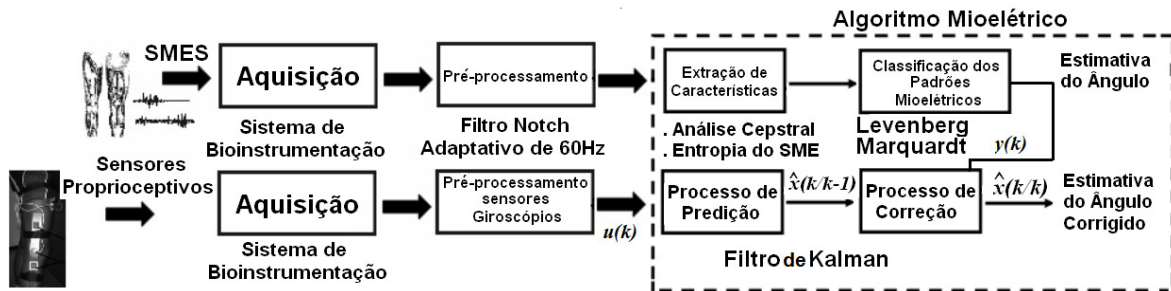


Figura 4.10 - Esquema de funcionamento da segunda variante de algoritmo mioelétrico.

no qual,  $x(k)$  representa a correção da estimativa do ângulo,  $u(k)$  é a informação da velocidade angular adquirida com um período de amostragem  $T$ , obtido a partir da diferença das velocidades angulares fornecidas pelos sensores giroscópios no músculo e na perna respectivamente;  $n(k)$  é o ruído que modela a evolução do ângulo de deslocamento do joelho entre dois intervalos de amostras;  $y(k)$  é a estimativa do ângulo do joelho, obtido na saída da rede neural perceptron multicamada e  $v(k)$  é o ruído da medição. É assumido que  $n(k)$  e  $v(k)$  apresentam média zero, são não-correlacionados com distribuição Gaussiana e variâncias  $q^2$  e  $r^2$ , respectivamente. A Figura 4.10 apresenta um esquema em blocos da segunda variante de algoritmo baseado em fusão de dados. Quando é aplicado o filtro de *Kalman* ao modelo, para cada ciclo de iteração no tempo discreto  $k$ , o processo de predição é descrito por meio das seguintes equações:

$$\text{Inicializa } r : q^2 = 4, r^2 = 10, x(1) = 0, \sigma_{uk}^2 = 25 \text{ e } P(1) = 0.01$$

$$\hat{x}(k/k-1) = \hat{x}(k-1) + T u(k) \quad (4.32)$$

$$P(k/k-1) = P(k-1) + T^2 \sigma_{uk}^2 + q^2, \quad (4.33)$$

no qual,  $\sigma_{uk}^2$  é a variância da informação da velocidade angular. O processo de correção é descrito de acordo com as equações (4.27), (4.28) e (4.29);  $\hat{x}(k/k)$  é uma estimativa ótima de  $x(k)$ . O valor é uma estimativa ótima do ângulo do deslocamento do joelho, a partir do processo de fusão, com informação da velocidade angular em cada ciclo de iteração no tempo discreto  $k$ .

#### 4.2.3.3 – Terceira variante de fusão de dados

A terceira variante incorpora (Figura 4.11) à variante anterior um teste de compatibilidade baseado na distância de *Mahalanobis* (De Maesschalck *et al.*, 2000; Duda *et al.*, 2000).

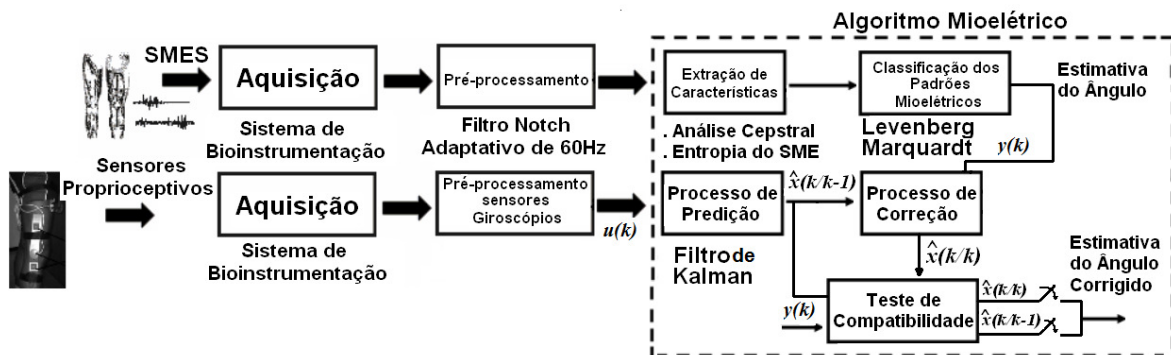


Figura 4.11 - Esquema de funcionamento da terceira variante de algoritmo mioelétrico.

A distância de *Mahalanobis* é uma forma útil para determinar a similaridade de um conjunto de amostras e apresenta como característica, a independência da escala de medição. A inserção de um teste de compatibilidade entre o processo de predição e correção do filtro de *Kalman* tem como alvo avaliar os possíveis artefatos provenientes da estimação do ângulo do joelho da rede perceptron multicamada, em cada passo do tempo, do processo de fusão de dados. O cálculo da distância de *Mahalanobis* é baseado na estimativa do desvio padrão da distância das amostras a partir de um centro de massa (Duda *et al.*, 2000), dado pelo a Equação 4.34.

$$d(x, y) = \sqrt{\sum_{i=1}^N \frac{(x_i - y_i)^2}{\sigma_{x_i}^2 + \sigma_{y_i}^2}}, \quad (4.34)$$

no qual,  $N$  representa o número de amostras,  $x_i$  e  $y_i$  representam as amostras a comparar para estabelecer sua similaridade, baseado em um limiar estatístico e  $\sigma_x$  e  $\sigma_y$  são os desvios padrões associados. Quando o filtro de *Kalman* é aplicado ao modelo estocástico linear descrito nas equações (4.30) e (4.31) para cada ciclo de iteração no tempo discreto:

O processo de predição é descrito por meio das equações (4.32) e (4.33). Depois de calculada a estimativa do ângulo a priori  $\hat{x}(k/k-1)$ , o teste de compatibilidade é calculado entre a estimativa do ângulo proveniente da rede neural perceptron multicamada ( $y(k)$ ), processo este que se implementa desde o início da estimação em paralelo ao filtro de *Kalman* e a estimativa do ângulo a priori, para cada ciclo de iteração no tempo discreto  $k$ , baseado na seguinte Equação:

$$d(x, y) = \sqrt{\sum_{k=1}^N \frac{(y(k) - \hat{x}(k/k-1))^2}{r^2 + P(k/k-1)}} \quad (4.35)$$

$$\hat{x}(k/k) = \begin{cases} \hat{x}(k/k-1) + G(k)(y(k) - \hat{x}(k/k-1)) & \text{se } d(x, y) < 1,96 \\ \hat{x}(k/k-1) & \text{caso contrario} \end{cases}$$

se o teste de compatibilidade é menor que 1,96, efetua-se o processo de correção do filtro de *Kalman*, de acordo com as equações (4.27), (4.28) e (4.29). Em cada ciclo de iteração no tempo discreto  $k$  se obtém  $\hat{x}(k/k)$  como uma estimativa ótima de  $x(k)$ , do ângulo do deslocamento do joelho, a partir do processo de fusão com informação da velocidade angular. Caso o teste seja maior ou igual a 1,96, poderia ser um indicador da presença de artefatos na estimativa do ângulo proveniente da rede neural perceptron multicamada; porém a estimativa ótima de  $x(k)$  é calculado a partir da estimativa do ângulo a priori  $\hat{x}(k/k-1)$ . O limiar estatístico 1,96 é escolhido baseado na tabela que apresenta as estatísticas da distribuição Qui-quadrado (Duda *et al.*, 2000). Utilizando como parâmetro de entrada na tabela o número de graus de liberdade, que é 1 (correspondente a uma amostra em cada ciclo de iteração), e o valor de  $P = 0,05$  para estabelecer que com um 5%

de erro as medidas sejam similarmente estatísticas, tem-se o valor de 3,84. Isso corresponde a um percentil de  $1-P = 0,95$  (ou 95%) da distribuição Qui-quadrado, que para a distância de *Mahalanobis*, esse limite seria  $\sqrt{3,84} = 1,96$ , que representa o percentil transformado na distância  $d(x, y)$ . Assim, enquanto  $d(x, y) < 1,96$ , pode-se afirmar que, com apenas 5% de erro, que as medidas são similares estatisticamente.

#### 4.2.4 – Configuração dos parâmetros para as variantes dos algoritmos mioelétricos

Da mesma forma que na seção anterior, o processo de obtenção da estimativa do ângulo de deslocamento do joelho foi implementado de forma *off-line* neste primeiro estágio da validação das variantes do algoritmo mioelétrico. Foram utilizados dois canais do SMES, dois sensores giroscópios e um canal de eletrogoniômetro, fazendo uso das ferramentas do *Matlab*. Um processo de treinamento, no qual as informações extraídas a partir da coleta de dados servem para treinar a rede neural perceptron multicamada, e outro, para o teste das variantes do algoritmo mioelétrico, avaliam seu desempenho e caracterizam a estimação do ângulo.

Para cada canal do SMES, as variantes propostas foram implementadas de forma que o processo de extração de características (análise cespstral e entropia do SMES) foi calculado para uma janela de 200 amostras (equivalentes a 192 ms, tendo em conta a frequência de amostragem para a implementação do segundo protocolo clínico). Foi utilizado um fator de ordem seis para o cálculo dos coeficientes cepstrais, obtido pelo método AR. Os coeficientes cepstrais e o valor da entropia são atualizados para cada nova amostra do SME. Finalmente, para cada amostra de entrada do processo de extração para cada canal do SME, obtém-se um vetor concatenado de 7 componentes correspondentes ao método de análise cepstral e à entropia. Similarmente, para cada nova amostra dos sensores giroscópios, a estimativa da velocidade angular e o ângulo de deslocamento do joelho são calculados a partir do filtro de *Kalman* para a primeira, segunda e terceira variante, respectivamente.

Para a primeira variante de algoritmo baseada em fusão de dados, um vetor característico de 15 coeficientes (6 coeficientes cepstrais e 1 coeficiente de entropia por



cada canal do SMES, mais um coeficiente da estimativa da velocidade angular) é obtido para cada nova amostra. Os coeficientes são transferidos às entradas da rede neural perceptron multicamada. Para as segunda e terceira variantes, um vetor característico de 14 coeficientes (6 coeficientes cepstrais e 1 coeficiente de entropia por cada canal do SMES) é obtido por intervalo de amostra. Os coeficientes são transferidos às entradas da rede neural perceptron multicamada que apresenta duas camadas em sua estrutura. A primeira camada é configurada com seis neurônios que utilizam a função de ativação tangente hiperbólica e uma camada de saída composta por um único neurônio cuja função de ativação é linear. A saída da rede representa a estimativa do ângulo (Figura 4.9a, b e c).

Para a primeira variante baseada em fusão de dados no processo de treinamento, os vetores de saída provenientes dos estágios de extração de características (análise cepstral, entropia do SMES e estimação da velocidade angular baseada no filtro de *Kalman*) são utilizados como entrada da rede. Nas segunda e terceira variantes, o processo de treinamento é composto pelos vetores de saída provenientes da análise cepstral e da entropia do SMES. A informação conhecida do deslocamento angular é obtida a partir do eletrogoniômetro. Os valores iniciais dos pesos são os mesmos para as três camadas da rede (valor zero para todos os neurônios). O número máximo de iterações é 50, com critério de parada baseado no erro quadrático médio de saída inferior a  $1e-10$ , sendo que a taxa de aprendizagem foi  $\eta = 1$ . A estrutura da rede neural perceptron multicamada, assim como seus parâmetros de aprendizagem, foi determinada com base em testes para se obter o melhor desempenho da mesma (redução do MSE). Nas segunda e terceira variantes, após obter a estimação do ângulo do joelho no processo de teste, a partir da rede perceptron multicamada, a estimativa é fusionada no processo de correção do filtro de *Kalman* com a informação da velocidade angular. Assim, obtém-se uma estimativa do ângulo de deslocamento do joelho corrigido na presença de possíveis artefatos.

### **4.3 – CONCLUSÃO DO CAPÍTULO**

O capítulo introduz duas estratégias de algoritmos mioelétricos para a estimação do ângulo do joelho a partir do SMES e fusão de dados entre os SMEs e sensores proprioceptivos. Estas podem ser usadas para o controle mioelétrico de uma prótese

transfemoral de perna. A primeira proposta de algoritmo é uma modificação do algoritmo originalmente apresentado em (Ferreira *et al.*, 2005) pela adição de um estágio de projeção de características (redes SOM) e o incremento no estágio de extração de características com o histograma de EMG. O processo de extração de características agora combina métodos no domínio do tempo (histograma) e método no domínio da frequência (coeficientes auto-regressivos). O processo de classificação de padrões com a rede neural perceptron multicamada se mantém, mas, com a adição do estágio de projeção de características. É mais eficiente, dada a redução de dimensionalidade proporcionadas pelas redes SOM.

Dada a significância da qualidade do espaço característico durante o processo de classificação, o estágio de extração de características é essencial na implementação dos algoritmos mioelétricos. Os estudos em Hargrove *et al.* (2008) mostraram que uma configuração como a utilizada na proposta de algoritmo representa alta exatidão de classificação e é computacionalmente eficiente, facilitando sua implementação em sistemas embarcados. A configuração é robusta a possíveis deslocamentos dos eletrodos de superfície.

Uma contribuição importante do estágio de projeção de características através das redes SOM é a redução do tempo de aprendizagem da rede supervisionada (rede perceptron multicamada), devido à redução de dimensionalidade do espaço de entrada. Cada grupo de coeficientes de alta dimensionalidade, associado a cada canal do SMES, é transformado em um mapa coordenado de duas dimensões (2-D) por meio das redes SOM. Os mapas auto-organizáveis podem também eliminar o ruído e as grandes variações que se apresentam no espaço característico de entrada (Delis *et al.*, 2009).

A rede perceptron multicamada do tipo *Levenberg-Marquardt* é eficiente quando se treinam redes com até centenas de neurônios em sua estrutura de interconexão (Hagan e Menhaj, 1994). Embora os requerimentos computacionais da rede se incrementem durante o processo de treinamento, isso é compensado pelo aumento em sua eficiência e na redução de seu tempo de convergência.

A integração ou fusão de informação redundante pode reduzir a incerteza, também pode incrementar a exatidão com as quais as características são detectadas pelo o algoritmo mioelétrico, além de incrementar a confiabilidade no caso de erro dos sensores. Três variantes de algoritmos mioelétricos baseados em fusão de dados entre sinais mioelétricos e sensores proprioceptivos são propostos neste capítulo, com o objetivo de melhorar a exatidão ante a presença de artefatos de diferentes naturezas. As variantes de algorítmicos oferecem a possibilidade da inserção de diferentes módulos de sensores proprioceptivos, através da fusão com o filtro de *Kalman*, no qual a formulação de predição – correção permite a obtenção de uma estimativa ótima. Os conceitos usados nestas variantes de algoritmos poderiam ser úteis no desenvolvimento de um controlador mioelétrico, no qual sinais a partir de diferentes sensores podem ser fusionados e usados na concepção de um modelo preditivo de movimento.

## 5– RESULTADOS E DISCUSSÃO

O presente capítulo apresenta os resultados obtidos pelos algoritmos propostos no Capítulo 4. Durante a avaliação das propostas são, utilizados indicadores qualitativos e quantitativos através de métricas estatísticas em uma comparação com a medida de informação angular fornecida pelo sensor eletrogoniômetro. Adicionalmente, é estabelecida uma comparação entre as propostas de algoritmos mioelétricos e métodos de extração e classificação de padrões já registrados na literatura (Wang *et al.*, 2006; Boostani e Moradi, 2003).

### 5.1– ESTIMAÇÃO DO ÂNGULO PARA A PRIMEIRA PROPOSTA DE ALGORITMO

A primeira proposta de algoritmo apresentada é uma melhoria em relação ao algoritmo de Ferreira *et al.*, (2005). O fator mais importante nos resultados obtidos na proposta do algoritmo é a inserção do estágio de projeção de características apresentada pelas redes SOM. Na proposta do algoritmo, a configuração de histograma mais AR é robusta com relação ao deslocamento de eletrodos. Isto foi corroborado durante o processo de validação da estimativa do ângulo feita com o sujeito A, na realização do protocolo experimental #1. A funcionalidade das redes SOM, embora dirigida ao processo de redução de dimensionalidade, permite absorver a energia do ruído do espaço característico e melhorar a separação dos *clusters* associados aos padrões mioelétricos.

A Figura 5.1 apresenta os resultados do ângulo medido (sensor eletrogoniômetro) e a estimativa (algoritmo mioelétrico) para os processos de treinamento e validação de um conjunto de dados para o sujeito #2 na implementação do protocolo experimental #2. Para reduzir o ruído impulsivo e a variância na estimativa do ângulo (Figura 5.1a), um filtro de média móvel é utilizado com implementação recursiva (Equação 5.1):

$$y(k) = \frac{1}{M} \sum_{j=0}^{M-1} x(k-j), \quad (5.1)$$

no qual,  $x$  é o sinal de entrada,  $y$  é a média no tempo discreto  $k$  e  $M$  o número de amostras no processo de obtenção do valor médio. O filtro mantém os níveis de inclinação presentes na estimativa do ângulo e apresenta um atraso de  $(M-1)/2$  amostras (Smith, 1999). Os resultados obtidos foram satisfatórios com 50 amostras, verificando-se redução do ruído impulsivo, decremento na variância e conservando-se as mudanças de níveis na estimativa do ângulo (Figura 5.1).




Figura 5.1 - Ângulos medidos e estimados dos processos de treinamento e validação para o sujeito #2: (a) treino; (b) validação; (c) validação filtrada.

## 5.2- ESTIMAÇÃO DO ÂNGULO PARA A SEGUNDA PROPOSTA DE ALGORITMO

A Figura 5.2 apresenta os resultados do ângulo medido (sensor eletrogoniômetro) e a estimativa das variantes da segunda proposta do algoritmo mioelétrico, baseada em fusão de dados. O processo de estimativa é efetuado no processo de validação de um conjunto de dados para o sujeito #2, na implementação do protocolo experimental #2.

Como se observa na Figura 5.2, as três variantes de algoritmos efetuam um ótimo percurso do ângulo medido com a ocorrência de artefatos discretos que, dependendo de sua duração, são imperceptíveis no controle do ângulo do joelho.




Figura 5.2 - Ângulos medidos e estimados do processo de validação para o sujeito #2: (a) primeira proposta; (b) segunda proposta; (c) terceira proposta.

### 5.3– ERRO MÉDIO QUADRÁTICO E NÚMERO DE PADRÕES DE ENTRADA

A Figura 5.3 apresenta a evolução do desempenho da rede neural perceptron multicamada ao longo de seu processo de treinamento (o número máximo de épocas é 50). É importante ressaltar que o número de épocas permite configurar o tempo de treinamento necessário e, conseqüentemente, reduzir o erro médio quadrático. A escolha do número de épocas foi empírica. Durante as avaliações dos algoritmos mioelétricos, foi verificado que com um número maior de épocas no processo de treino, os resultados não foram significativos nos índices quantitativos.




Figura 5.3 - Comparação do erro médio quadrático e número de padrões de entrada durante o treinamento da rede LM.

Embora os requerimentos computacionais da rede perceptron multicamada aumentem no processo de treinamento (a cada iteração) pelo cálculo da matriz Jacobiana, isso é compensado por um incremento em sua eficiência e por uma redução no tempo de convergência do mesmo. Hagan e Menhaj (1994) apresentam comparações entre a rede perceptron multicamada do tipo LM e modificações feitas no algoritmo *back-propagation* baseadas no gradiente conjugado e na taxa de aprendizagem variável; resultam, para alguns casos, em falhas na convergência para as modificações realizadas, no entanto, para os mesmo testes, a rede perceptron multicamada do tipo LM convergiu com resultados aceitáveis. Os resultados indicam que a rede é muito eficiente quando se treina com centenas de neurônios em sua estrutura de interconexão (Hagan e Menhaj, 1994).

#### 5.4- COMPARAÇÃO UTILIZANDO OUTRAS VARIANTES DE ALGORITMOS MIOELÉTRICOS

Para avaliar o desempenho dos métodos propostos (Delis *et al.*, 2009; Delis *et al.*, 2010), foi estabelecida uma comparação com outros já existentes na literatura relacionados com algoritmos de extração e classificação de padrões mioelétricos:

1. O algoritmo desenvolvido por Ferreira *et al.*, (2005) que foi a primeira proposta utilizada para extração de características da intenção de movimento a partir dos SMEs para aplicar no projeto da prótese de perna. O algoritmo apresenta o método RLS e a rede neural perceptron multicamada com algoritmo de treinamento do tipo LM como extração de características e classificação de padrões, respectivamente. A primeira proposta de algoritmo (Delis *et al.*, 2009) é uma modificação do anterior, incorporando o histograma de EMG e o estágio de projeção de características, como foi explicado anteriormente (Figura 5.4);
2. *Wavelet Packets (Energy Wavelet Packets, EWP)* como método de extração de características e análise de componentes principais como estágio de redução de dimensionalidade (EWP-PCA) (Wang *et al.*, 2006, Boostani e Moradi, 2003). Primeiramente, a energia dos coeficientes foi utilizada para classificar os sinais mioelétricos. Cada sinal foi descomposto utilizando *wavelet packets transform* (a um quarto nível pela *wavelet Symlet 5*), e a energia relativa de cada subespaço foi calculada (Wang *et al.*, 2006). Um vetor característico com 30 coeficientes foi construído. Posteriormente, a análise de componentes principais foi aplicada, sendo que os vetores resultantes da transformação linear constituem a entrada do estágio de classificação de padrões mioelétricos. Neste último, foi utilizada a mesma configuração que no algoritmo proposto através da rede neural perceptron multicamada, com a mesma estrutura de camadas em sua interconexão (Figura 5.4). O algoritmo mioelétrico foi escolhido tendo em conta que apresenta outra proposta de extração de característica (domínio tempo-escala) e projeção de característica (PCA) como métodos para o processo de classificação dos padrões mioelétricos.

O mesmo conjunto de dados para treino e validação utilizados nas propostas de algoritmos foi empregado na comparação com os algoritmos Ferreira *et al.*, (2005) e Wang *et al.*, (2006), (Figura 5.4). Para manter uma consistência com a implementação do método proposto, no método EWP-PCA foi utilizada uma janela de 200 amostras (115 ms e 192 ms durante a implementação do primeiro e segundo protocolo clínico, respectivamente) com atualização para cada nova amostra do SME, de forma que o processo de decomposição do EWP foi recalculado para cada nova amostra. A mesma ordem do



modelo auto-regressivo com fator de esquecimento também foi utilizada para a implementação do método EWP-PCA. Várias métricas estatísticas foram avaliadas nos algoritmos mioelétricos e serão descritas a seguir.

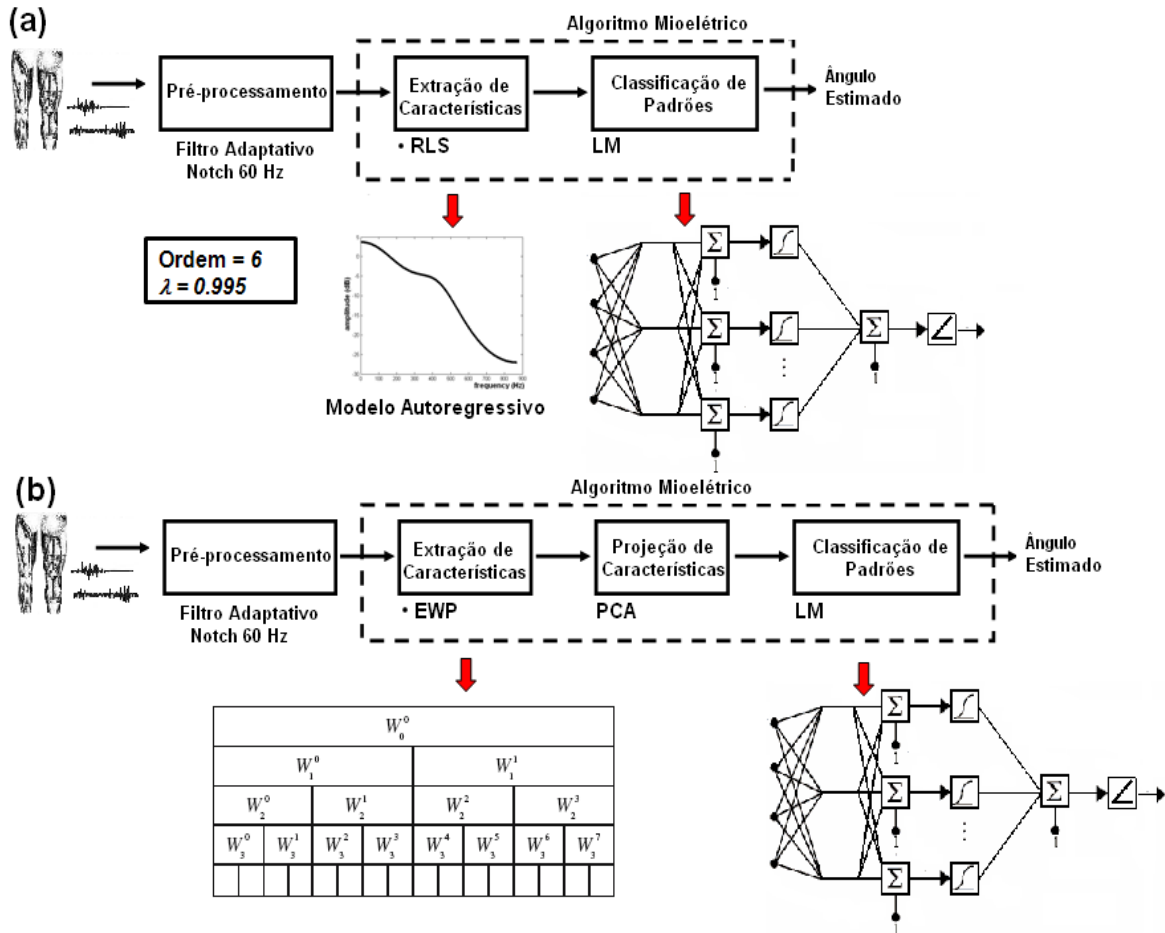


Figura 5.4 - Algoritmos mioelétricos utilizados para as comparações com as propostas desenvolvidas: (a) Ferreira *et al.* (2005); (b) Wang *et al.* (2006).

### 5.4.1- MÉTRICAS ESTADÍSTICAS DE COMPARAÇÃO

Para efetuar comparações entre as propostas de algoritmos mioelétricos e os já registrados na literatura, foram utilizados um conjunto de métricas estatísticas que serão descritas a seguir:

O percentual do erro de classificação foi obtido a partir da Equação 5.2:

$$erro = \sqrt{\frac{\sum_{i=1}^N |x(i) - \hat{x}(i)|^2}{\sum_{i=1}^N |x(i)|^2}} \times 100(\%). \quad (5.2)$$

no qual,  $x(i)$  e  $\hat{x}(i)$  representam os vetores de valores angulares obtidos do eletrogoniômetro e da estimativa do ângulo, respectivamente; e  $N$  é a dimensão de ambos os vetores. O coeficiente de correlação  $r$  entre duas variáveis aleatórias  $x$  e  $y$  com  $N$  amostras e valores esperados  $\bar{x}$  e  $\bar{y}$  é definido como (Ropella, 2007):

$$r = \frac{\sum_{i=0}^{N-1} (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=0}^{N-1} (x_i - \bar{x})^2 \sum_{i=0}^{N-1} (y_i - \bar{y})^2}} \quad (5.3)$$

O coeficiente fornece uma medida do grau de dependência linear entre duas variáveis. O mesmo assume um valor entre -1 e +1. Valores negativos indicam correlação negativa; valores positivos indicam correlação positiva, e  $r = 0$  é um indicador de independência linear.

Os eventos de erro podem ser classificados como: grandes ou pequenos e isolados ou longos (Delis *et al.*, 2009). É óbvio que grandes e longos eventos de erro são mais críticos que os pequenos e isolados, dado que a inércia mecânica da prótese tende a filtrar os ruídos impulsivos. Tendo em vista o anterior, três métricas foram utilizadas para obter estatísticas dos eventos de erro (séries isoladas ou longas, com grandes erros de classificação). As métricas efetuam as medições do número, amplitude e duração dos eventos de erro. Os erros de estimação nas séries temporais associados ao grupo de sinais de validação foram calculados com base na diferença absoluta entre o ângulo de deslocamento do joelho medido pelo eletrogoniômetro, e a estimativa do deslocamento angular medidas pelas propostas dos algoritmos mioelétricos.

Para efetuar a detecção dos eventos de erro, um limiar foi estabelecido. Os valores de erro que ficam abaixo do limiar são colocados em zero; os valores que ficam acima são considerados eventos de erro. O limiar utilizado na comparação dos algoritmos foi escolhido empiricamente, baseado em experimentos, e seu valor foi fixado em 10 graus (Delis *et al.*, 2009). Os eventos de erro foram segmentados da seguinte forma: (1) detectando o começo do evento, a partir de um valor não-zero encontrado depois de uma série de zeros; e (2), detectando o final do evento, a partir de um valor de zero encontrado após de uma série de valores não zeros. Logo, para cada evento de erro, a duração (número de amostras) e a máxima amplitude do erro foram calculadas.

#### 5.4.2– DETERMINAÇÃO DA SIGNIFICÂNCIA ESTATÍSTICA

Para a determinação da significância estatística na avaliação das propostas dos algoritmos, a análise de Anova não foi utilizada, dado que as métricas estatísticas são não-homoscedásticas; acontece quando as variáveis não apresentam as mesmas variâncias (Hamilton, 1994). Alternativamente, foi utilizada a distância de *Mahalanobis*, dada pela Equação 5.4.

$$d(x, y) = \sqrt{\frac{\sum_{i=1}^N (\bar{x}_i - \bar{y}_i)^2}{\sigma_{x_i}^2 + \sigma_{y_i}^2}}, \quad (5.4)$$

no qual,  $N$  representa o número de sujeitos,  $\bar{x}_i$  e  $\bar{y}_i$  representam as médias intra-sujeitos para dois diferentes algoritmos, e  $\sigma_{x_i}$  e  $\sigma_{y_i}$  são os desvios padrões associados. A distância de *Mahalanobis* é aplicável a populações com diferentes variâncias, útil para determinar a similaridade de um conjunto de amostras e não é dependente da escala de medição (Duda *et al.*, 2000).

### 5.4.3– RESULTADOS DA COMPARAÇÃO PARA A PRIMEIRA PROPOSTA DE ALGORITMO MIOELÉTRICO

As Tabelas 5.1 e 5.2 apresentam os resultados do percentual erro–sinal e o coeficiente de correlação (valores de deslocamento angular medido e sua estimativa), na comparação entre a primeira proposta de algoritmo, o algoritmo de Ferreira *et al.* (2005) e o algoritmo EWP–PCA. Os resultados apresentam a média e o desvio padrão dos quatro voluntários para o grupo de sinais de validação na implementação do protocolo experimental #1.

Tabela 5.1 - Comparação entre os algoritmos baseados no percentual erro–sinal (algoritmo Ferreira *et al.*, (2005), algoritmo EWP–PCA e primeira proposta de algoritmo).

Sujeitos	Percentual erro–sinal ( $\mu \pm \sigma$ )		
	Ferreira <i>et al.</i> (2005)	EWP–PCA	Alg. proposto
Sujeito A	8,02% $\pm$ 4,21%	9,45% $\pm$ 2,58%	6,56% $\pm$ 1,85%
Sujeito B	8,18% $\pm$ 4,70%	7,12% $\pm$ 1,22%	5,33% $\pm$ 1,13%
Sujeito C	6,54% $\pm$ 4,36%	6,51% $\pm$ 4,03%	5,77% $\pm$ 3,64%
Sujeito D	6,63% $\pm$ 3,06%	7,54% $\pm$ 3,17%	5,23% $\pm$ 1,47%

Tabela 5.2 - Comparação entre os algoritmos baseados no coeficiente de correlação (algoritmo Ferreira *et al.*, (2005), algoritmo EWP–PCA e primeira proposta de algoritmo).

Sujeitos	Coeficiente de correlação ( $\mu \pm \sigma$ )		
	Ferreira <i>et al.</i> (2005)	EWP–PCA	Alg. proposto
Sujeito A	0,75 $\pm$ 0,20	0,52 $\pm$ 0,20	0,84 $\pm$ 0,07
Sujeito B	0,54 $\pm$ 0,27	0,30 $\pm$ 0,22	0,61 $\pm$ 0,22
Sujeito C	0,59 $\pm$ 0,16	0,27 $\pm$ 0,16	0,59 $\pm$ 0,20
Sujeito D	0,71 $\pm$ 0,17	0,34 $\pm$ 0,19	0,72 $\pm$ 0,09

As Tabelas 5.3, 5.4 e 5.5 apresentam os resultados do número de eventos de erro, bem como amplitude e duração máxima, na comparação entre a primeira proposta de algoritmo, o algoritmo de Ferreira *et al.* (2005) e o algoritmo EWP–PCA, respectivamente.

Os resultados apresentam a média e o desvio padrão para o grupo de sinais de validação dos quatro voluntários na implementação do protocolo experimental #1.

Tabela 5.3 - Comparação entre os algoritmos baseado nos eventos de erro (algoritmo Ferreira *et al.*, (2005), algoritmo EWP-PCA e primeira proposta de algoritmo).

Sujeitos	Número de eventos de erro ( $\mu \pm \sigma$ )		
	Ferreira <i>et al.</i> (2005)	EWP-PCA	Alg. proposto
Sujeito A	45 ± 10	252 ± 64	27 ± 5
Sujeito B	71 ± 15	240 ± 71	32 ± 11
Sujeito C	34 ± 11	181 ± 63	18 ± 6
Sujeito D	51 ± 12	192 ± 44	28 ± 8

Tabela 5.4 - Comparação entre os algoritmos baseados na máxima amplitude dos eventos de erro (algoritmo Ferreira *et al.*, (2005), algoritmo EWP-PCA e primeira proposta de algoritmo).

Sujeitos	Amplitude ( $\mu \pm \sigma$ )		
	Ferreira <i>et al.</i> (2005)	EWP-PCA	Alg. proposto
Sujeito A	76° ± 48°	98° ± 67°	42° ± 11°
Sujeito B	61° ± 49°	161° ± 48°	30° ± 7°
Sujeito C	47° ± 27°	158° ± 69°	29° ± 12°
Sujeito D	50° ± 36°	130° ± 71°	33° ± 11°

Tabela 5.5 - Comparação entre os algoritmos baseados na duração dos eventos de erro (algoritmo EWP-PCA, algoritmo EWP-PCA e primeira proposta de algoritmo).

Sujeitos	Duração ( $\mu \pm \sigma$ )		
	Ferreira <i>et al.</i> (2005)	EWP-PCA	Alg. proposto
Sujeito A	433 ms ± 154 ms	441 ms ± 82 ms	450 ms ± 206 ms
Sujeito B	398 ms ± 105 ms	385 ms ± 71 ms	377 ms ± 187 ms
Sujeito C	719 ms ± 442 ms	500 ms ± 293 ms	691 ms ± 512 ms
Sujeito D	413 ms ± 183 ms	400 ms ± 160 ms	339 ms ± 132 ms

A Tabela 5.6 apresenta o cálculo da significância estatística para as diferentes métricas, através da distância de *Mahalanobis* entre o algoritmo proposto, o algoritmo de Ferreira *et al.*, (2005) e o algoritmo EWP-PCA, respectivamente.

Tabela 5.6 - Significância estatística obtida na comparação dos algoritmos mioelétricos.

Métricas estatísticas	Algoritmo proposto e algoritmo Ferreira <i>et al.</i> , (2005)	Algoritmo proposto e algoritmo EWP-PCA
Percentual erro-sinal	0,80	1,56
Coefficiente de correlação	0,47	2,58
Número de eventos de erro	3,34	6,38
Duração máxima	0,35	0,44
Amplitude máxima	1,19	3,63

Para  $N = 4$ , os resultados das comparações entre os diferentes algoritmos são considerados estatisticamente significativos se o cálculo da distância de *Mahalanobis*, dado pela Equação 5.4, resulta em  $d > 3,08$ . O limiar estatístico 3,08 é escolhido baseado na tabela que apresenta as estatísticas da distribuição Qui-quadrado (Duda *et al.*, 2000). Utilizando como parâmetro de entrada na tabela o número de graus de liberdade, que é 4, e o valor de  $P = 0,05$ , tem-se o valor de 9,49. Isso corresponde a um percentil de  $1-P = 0,95$  (ou 95%) da distribuição Qui-quadrado, que para a distância de *Mahalanobis*, esse limite seria  $\sqrt{9,49} = 3,08$ , que representa o percentil transformado na distância  $d(x, y)$ . Assim, para  $d(x, y) < 3,08$ , pode-se afirmar, com apenas 5% de erro, que as medidas são similares estatisticamente.

Para avaliar o desempenho desta primeira proposta de algoritmo, foi implementado um primeiro protocolo experimental para quatro indivíduos saudáveis, através do sistema de bioinstrumentação, utilizando dois canais do SMES e um sensor eletrogoniômetro. A partir dos resultados obtidos na Tabela 5.6, mostra-se que, embora o baixo percentual erro-sinal e maior coeficiente de correlação que apresenta a primeira proposta de algoritmo com respeito aos algoritmos Ferreira *et al.* (2005) e EWP-PCA (Tabela 5.1 e 5.2), ambas as métricas estatísticas não são significativas em sua

comparação. Acredita-se que isto se deve a uma exatidão na estimativa do ângulo a partir dos algoritmos mioelétricos em relação aos valores de deslocamento angular do eletrogoniômetro (Figura 5.5).

O algoritmo proposto apresenta resultados equivalentes quanto à amplitude, duração máxima e significativamente menor número de eventos de erro com respeito ao algoritmo Ferreira *et al.*, (2005). Em relação ao algoritmo EWP-PCA, a proposta de algoritmo apresenta resultados equivalentes quanto à duração máxima e significativamente baixos índices de número e amplitude máxima de eventos de erro (Tabela 5.6). É importante enfatizar que não todos os eventos de erro são falsos positivos; alguns são distúrbios no deslocamento do ângulo em relação aos valores do eletrogoniômetro e os mesmos acompanham o percurso do ângulo medido o mais próximo possível (Figura 5.5a). Observa-se que, além da redução significativa do número de eventos de erro e amplitude máxima que apresenta a proposta de algoritmo, a duração máxima permanece equivalente em relação aos outros algoritmos. A provável causa poderia ser o ruído no espaço característico dos coeficientes AR e do histograma. Embora sua amplitude se reduzisse com a inserção do estágio de projeção de característica, o mesmo comportamento não é manifestado quanto à duração dos eventos de erro.

Quando é aplicada a primeira proposta, a máxima amplitude dos eventos de erro é significativamente reduzida em comparação ao algoritmo EWP-PCA. No entanto, persistem consideráveis níveis de amplitudes nos mesmos. Do ponto de vista prático, dependendo da duração do evento de erro, a própria inércia mecânica associada ao controle do motor poderia filtrar os picos e evitar os possíveis distúrbios no funcionamento da prótese. A magnitude dos eventos de erro poderia ser explicado pelo ruído no espaço de vetores característicos ou por um insuficiente número de neurônios que representa a matriz topológica na rede SOM e na camada oculta da rede LM, o que faz com que a aprendizagem da rede não seja ótima. No entanto, o aumento no número de neurônios aumentaria a carga computacional do algoritmo. Assim, existe um compromisso entre a exatidão e tempo de resposta do sistema. Algumas soluções poderiam ser o incremento de mais canais mioelétricos e sensores relacionados à propriocepção (giroscópios). Conforme foi mencionado anteriormente, isto aumentaria a exatidão na classificação.

Alternativamente, os picos de erro poderiam ser reduzidos, aumentando tanto o fator de esquecimento no algoritmo RLS como o comprimento da janela no histograma. No entanto, esta solução poderia aumentar o tempo de resposta no acionamento da prótese.

#### **5.4.4– RESULTADOS DA COMPARAÇÃO PARA A SEGUNDA PROPOSTA DE ALGORITMO MIOELÉTRICO**

A seguir, apresenta-se uma comparação entre as três variantes de algoritmos mioelétricos, baseadas em fusão de dados ou seja, a partir dos SMEs e sensores proprioceptivos; com a primeira proposta de algoritmo, os algoritmos Ferreira *et al.*, (2005) e EWP-PCA. A comparação é baseada nas métricas estáticas explicadas anteriormente, na implementação de testes nos algoritmos ante a presença de artefatos (indução de movimento dos cabos conectados aos sensores) e interferência na rede elétrica. As Tabelas 5.7 e 5.8 apresentam os resultados do percentual erro-sinal e o coeficiente de correlação (valores de deslocamento angular medido e sua estimativa). Os resultados apresentam a média e o desvio padrão para o grupo de sinais de validação de doze indivíduos saudáveis voluntários na implementação do protocolo experimental #2. Para isso, foi utilizado o sistema de bioinstrumentação, utilizando dois canais dos SMES, um sensor eletrogoniômetro e dois sensores giroscópios.



Tabela 5.7 - Comparação baseada no percentual erro-sinal entre: (A) primeira variante, (B) segunda variante, (C) terceira variante, (D) algoritmo Ferreira *et al.*, (2005), (E) primeira proposta de algoritmo e (F) método EWP-PCA.

Sujeitos	Percentual erro-sinal em % ( $\mu \pm \sigma$ )					
	A	B	C	D	E	F
#1	5,11±0,99	5,76±1,28	4,63±0,55	6,73±2,47	6,84±1,68	8,74±2,08
#2	5,67±1,65	5,85±1,49	5,93±1,71	5,84±2,16	5,88±1,21	9,20±1,98
#3	6,03±2,00	7,00±1,96	6,41±1,87	7,37±2,40	6,98±1,68	9,15±2,28
#4	7,61±3,10	7,58±3,28	7,99±3,34	7,58±2,99	8,32±1,68	13,6±4,70
#5	6,76±2,44	6,73±2,31	6,77±2,42	6,53±2,89	8,12±2,88	9,08±3,27
#6	5,63±1,26	6,09±1,32	7,35±2,32	6,61±1,8	6,92±1,05	11,12±3,0
#7	7,63±2,03	8,31±1,84	7,50±2,03	7,88±2,79	9,31±2,80	11,65±1,9
#8	5,27±1,33	5,48±1,43	5,29±1,23	5,78±1,38	5,66±1,58	9,44±2,29
#9	6,23±1,69	6,45±1,19	6,58±1,62	6,61±1,58	6,35±1,41	9,38±2,01
#10	6,06±1,39	6,70±1,77	6,58±1,42	6,67±1,52	7,48±1,84	11,18±2,1
#11	7,04±1,32	6,98±0,74	7,15±0,80	7,13±1,57	7,37±1,97	10,16±2,5
#12	5,73±0,94	5,95±1,10	6,02±1,00	6,26±1,43	6,48±1,43	8,99±1,81

Tabela 5.8 - Comparação baseada no coeficiente de correlação.

Sujeitos	Coeficiente de correlação ( $\mu \pm \sigma$ )					
	A	B	C	D	E	F
#1	0,83±0,09	0,84±0,04	0,86±0,03	0,78±0,13	0,79±0,09	0,54±0,19
#2	0,86±0,07	0,85±0,04	0,86±0,05	0,79±0,19	0,80±0,13	0,40±0,21
#3	0,77±0,21	0,73±0,19	0,75±0,17	0,71±0,21	0,70±0,21	0,45±0,23
#4	0,80±0,24	0,86±0,08	0,83±0,17	0,85±0,06	0,76±0,16	0,31±0,30
#5	0,74±0,10	0,72±0,13	0,71±0,13	0,73±0,13	0,69±0,15	0,40±0,22
#6	0,87±0,04	0,86±0,04	0,81±0,09	0,82±0,08	0,81±0,06	0,41±0,29
#7	0,78±0,14	0,70±0,22	0,76±0,15	0,72±0,29	0,58±0,28	0,24±0,25
#8	0,85±0,09	0,84±0,09	0,85±0,10	0,81±0,07	0,84±0,13	0,40±0,19
#9	0,82±0,09	0,80±0,07	0,79±0,08	0,77±0,13	0,78±0,11	0,35±0,26
#10	0,86±0,08	0,83±0,11	0,84±0,11	0,83±0,10	0,75±0,17	0,38±0,20
#11	0,77±0,12	0,77±0,10	0,75±0,11	0,75±0,11	0,72±0,18	0,37±0,29
#12	0,83±0,09	0,82±0,06	0,83±0,05	0,79±0,10	0,76±0,09	0,44±0,18

Tabela 5.9 - Comparação baseada no número de eventos de erro.

Sujeitos	Número de eventos de erro ( $\mu \pm \sigma$ )					
	A	B	C	D	E	F
#1	35±8	30±8	30±5	32±10	24±7	156±46
#2	29±11	27±8	24±8	31±10	22±7	131±30
#3	50±10	40±12	39±13	44±13	36±8	154±59
#4	30±11	25±8	27±8	32±9	23±5	140±41
#5	29±14	26±14	24±10	29±14	24±11	149±86
#6	33±9	28±9	29±12	27±10	25±8	136±40
#7	39±13	34±6	37±13	34±11	28±10	144±42
#8	31±6	25±9	23±6	33±10	21±7	159±43
#9	43±13	36±14	35±12	43±16	27±9	124±47
#10	38±13	29±6	33±7	45±12	34±11	153±56
#11	43±13	34±10	30±7	45±18	29±7	138±44
#12	39±9	27±11	32±11	43±17	31±17	31±6

Tabela 5.10 - Comparação baseada na amplitude máxima dos eventos de erro.

Sujeitos	Amplitude em graus ( $\mu \pm \sigma$ )					
	A	B	C	D	E	F
#1	33±5	33±5	39±8	39±6	37±6	122±70
#2	28±7	32±10	28±8	34±21	29±5	61±39
#3	34±9	44±10	33±8	43±11	37±6	71±45
#4	38±10	41±14	39±15	39±10	40±8	91±50
#5	36±13	36±15	36±14	32±14	44±18	63±38
#6	30±4	31±6	37±15	39±8	39±8	84±45
#7	36±12	39±10	34±8	37±9	37±9	80±44
#8	27±10	30±6	28±13	27±8	27±10	89±47
#9	31±7	33±7	34±10	32±7	33±9	75±47
#10	37±10	45±24	38±12	38±11	41±11	100±56
#11	39±9	37±7	33±5	36±8	37±12	97±47
#12	36±9	43±14	31±5	39±10	39±8	96±54

Tabela 5.11 - Comparação baseada na duração máxima dos eventos de erro.

Sujeitos	Duração em ms ( $\mu \pm \sigma$ )					
	A	B	C	D	E	F
#1	470±115	473±102	510±133	619±201	585±138	575±78
#2	451±152	466±168	556±158	451±142	448±157	621±128
#3	437±225	501±178	462±200	587±323	530±212	548±273
#4	758±368	920±651	807±539	952±883	833±267	982±218
#5	614±111	526±154	645±155	582±337	674±325	710±315
#6	683±333	785±342	773±268	895±297	787±147	1119±288
#7	739±357	738±346	740±446	779±386	795±272	960±412
#8	369±194	448±186	407±130	471±197	406±146	719±235
#9	555±266	522±208	543±251	576±164	507±248	670±131
#10	584±190	628±148	621±134	618±171	679±278	957±296
#11	664±205	552±127	804±337	620±220	618±239	842±378
#12	629±192	677±191	730±339	688±226	659±531	869±334

As Tabelas 5.9, 5.10 e 5.11 apresentam os resultados do número de eventos de erro, bem como amplitude e duração máxima, entre as três variantes de algoritmos mioelétricos, baseadas em fusão de dados a partir dos SMEs e sensores proprioceptivos; com a primeira proposta de algoritmo, os algoritmos Ferreira *et al.*, (2005) e EWP-PCA. Os resultados apresentam a média e o desvio padrão para o grupo de sinais de validação dos doze voluntários na implementação do protocolo experimental #2.

De forma similar à comparação efetuada com a primeira proposta de algoritmo, a distância de *Mahalanobis* foi utilizada para avaliar a significância estatística entre cada uma das variantes de algoritmos baseados em fusão de dados com a primeira proposta de algoritmo, os algoritmos Ferreira *et al.*, (2005) e EWP-PCA. Para  $N = 12$ , os resultados das comparações entre os diferentes algoritmos são considerados estatisticamente significativos se o cálculo da distância de *Mahalanobis*, dado pelo a equação 5.4, resulta em  $d > 4,58$ . O limiar estatístico 4,58 é escolhido baseado na tabela que apresenta as estatísticas da distribuição Qui-quadrado (Duda *et al.*, 2000). Utilizando como parâmetro de entrada na tabela o número de graus de liberdade, que é 12, e o valor de  $P = 0,05$ , tem-se o valor de 21,03. Isso corresponde a um percentil de  $1-P = 0,95$  (ou 95%) da distribuição Qui-quadrado, que para a distância de *Mahalanobis*, esse limite seria  $\sqrt{21.03} = 4,58$ , que representa o percentil transformado na distância  $d(x, y)$ . Assim, para  $d(x, y) < 4,58$ , pode-se

afirmar que, com apenas 5% de erro, que as medidas são similares estatisticamente. As Tabelas 5.12, 5.13 e 5.14 apresentam os resultados da avaliação da significância estatística entre as três variantes de algoritmos baseados em fusão de dados, e a primeira proposta de algoritmo, os algoritmos Ferreira *et al.* (2005) e EWP-PCA.

Tabela 5.12 - Significância estatística obtida na comparação entre a primeira variante de algoritmo baseada em fusão de dados com o algoritmo Ferreira *et al.* (2005), e a primeira proposta de algoritmo e o método EWP-PCA.

Métricas estatísticas	Algoritmo Ferreira <i>et al.</i> , (2005)	Primeira proposta de algoritmo	Algoritmo EWP-PCA
Percentual erro-sinal	1,02	1,61	4,86
Coefficiente de correlação	1,09	1,59	5,89
Número de eventos de erro	0,90	2,67	7,78
Amplitude máxima	19,11	17,30	5,09
Duração máxima	1,97	0,90	2,48

Tabela 5.13 - Significância estatística obtida na comparação da segunda variante de algoritmo baseada em fusão de dados com o algoritmo Ferreira *et al.* (2005), e a primeira proposta de algoritmo e o método EWP-PCA.

Métricas estatísticas	Algoritmo Ferreira <i>et al.</i> , 2005	Primeira proposta de algoritmo	Algoritmo EWP-PCA
Percentual erro-sinal	0,52	1,00	4,37
Coefficiente de correlação	0,84	1,37	5,78
Número de eventos de erro	1,82	1,33	8,25
Amplitude máxima	1,24	1,27	3,41
Duração máxima	2,16	0,87	2,27

Tabela 5.14 - Significância estatística obtida na comparação da terceira variante de algoritmo baseada em fusão de dados com o algoritmo Ferreira *et al.* (2005), e a primeira proposta de algoritmo e o método EWP-PCA.

Métricas estatísticas	Algoritmo Ferreira <i>et al.</i> , (2005)	Primeira proposta de algoritmo	Algoritmo EWP-PCA
Percentual erro-sinal	0,98	1,53	4,58
Coefficiente de correlação	0,90	1,37	5,83
Número de eventos de erro	1,80	1,21	8,27
Amplitude máxima	0,96	1,07	3,57
Duração máxima	2,20	0,85	2,02

A partir dos resultados obtidos na Tabela 5.12 na avaliação da significância estatística da primeira variante de algoritmo mioelétrico baseado em fusão de dados, mostra-se que os resultados obtidos em quase todas as métricas estatísticas são equivalentes aos resultados do algoritmo Ferreira *et al.* (2005) e à primeira proposta de algoritmo com a exceção da amplitude máxima de eventos de erro, onde a primeira variante apresenta resultados significativos. Isto indica uma similaridade do desempenho dos algoritmos na estimação do ângulo em relação aos valores de deslocamento angular do eletrogoniômetro. Com respeito ao algoritmo EWP-PCA, a primeira variante apresenta significativamente baixos níveis de percentual erro-sinal, coeficiente de correlação, número de eventos de erro e amplitude máxima e resultados equivalentes quanto à duração máxima. A segunda e terceira variantes de algoritmo mioelétrico baseado em fusão de dados (Tabela 5.13 e 5.14) apresentam resultados não significativos, na comparação de todas as métricas estatísticas com relação ao algoritmo Ferreira *et al.* (2005) e à primeira proposta de algoritmo. Na comparação com respeito ao algoritmo EWP-PCA, ambas as variantes apresentam significativos resultados quanto ao coeficiente de correlação e ao número de eventos de erro, e resultados equivalentes quanto ao percentual erro-sinal, amplitude e duração máxima. A Figura 5.5 apresenta os resultados do ângulo medido, a estimativa e sua diferença absoluta para uma coleta de dados representativa durante o processo de validação do sujeito #8. Os resultados são apresentados para os algoritmos Ferreira *et al.* (2005), primeira proposta de algoritmo, método EWP-PCA e as três variantes de algoritmos baseados em fusão de dados entre os SMES e sensores proprioceptivos.

É importante enfatizar que os testes implementados nesta primeira fase de concepção dos algoritmos mioelétricos foram realizados em modo off-line. Não se levou em conta como o aumento do número de canais dos SMES poderia influenciar no desempenho da rede perceptron multicamada, fundamentalmente no tempo de convergência, dada a resposta que o sistema precisa para o acionamento da prótese de perna (menor ou igual a 300 ms). Isto poderia afetar o desempenho do algoritmo Ferreira *et al.* (2005). Neste aspecto, a primeira proposta de algoritmo fornece a redução de dimensionalidade que possibilita a conexão de um maior número de sensores SMES sem afetar consideravelmente o desempenho da rede perceptron multicamada. Outro aspecto a

considerar é a possibilidade que fornece a segunda proposta de algoritmo com suas três variantes na integração de sensores de diversa natureza, além dos SMES, através do processo de fusão. Espera-se que, quanto maior o número de informação fornecida ao algoritmo mioelétrico no processo de estimação do ângulo de deslocamento, melhor será a exatidão obtida para controle da prótese. O resultado da significância estatística na primeira variante de algoritmo mioelétrico baseado em fusão de dados apresenta uma redução significativa da amplitude máxima de eventos de erro. Isto enfatiza o efeito de fusionar na rede perceptron multicamada às informações do processo de extração de características proveniente dos coeficientes cepstrais e entropia com a filtragem passa-baixa obtida através do filtro de *Kalman*, reduzindo a amplitude do ruído na estimação do ângulo do joelho.

Em uma comparação qualitativa através da Figura 5.5, na estimação do ângulo de deslocamento do joelho entre os algoritmos, pode-se verificar os resultados equivalentes que os mesmos apresentam sendo moderadamente menor a qualidade no algoritmo EWP-PCA. A Figura 5.6 apresenta uma comparação qualitativa nos resultados do ângulo medido, a estimativa e sua diferença absoluta, o coeficiente de correlação, o número de eventos de erro e a amplitude máxima para uma coleta de dados com indução de artefatos (movimento dos cabos conectados aos sensores) para o sujeito #4. Os resultados são apresentados para os algoritmos de Ferreira *et al.* (2005), primeira proposta de algoritmo, método EWP-PCA e as três variantes de algoritmos baseados em fusão de dados entre os SMES e sensores proprioceptivos.

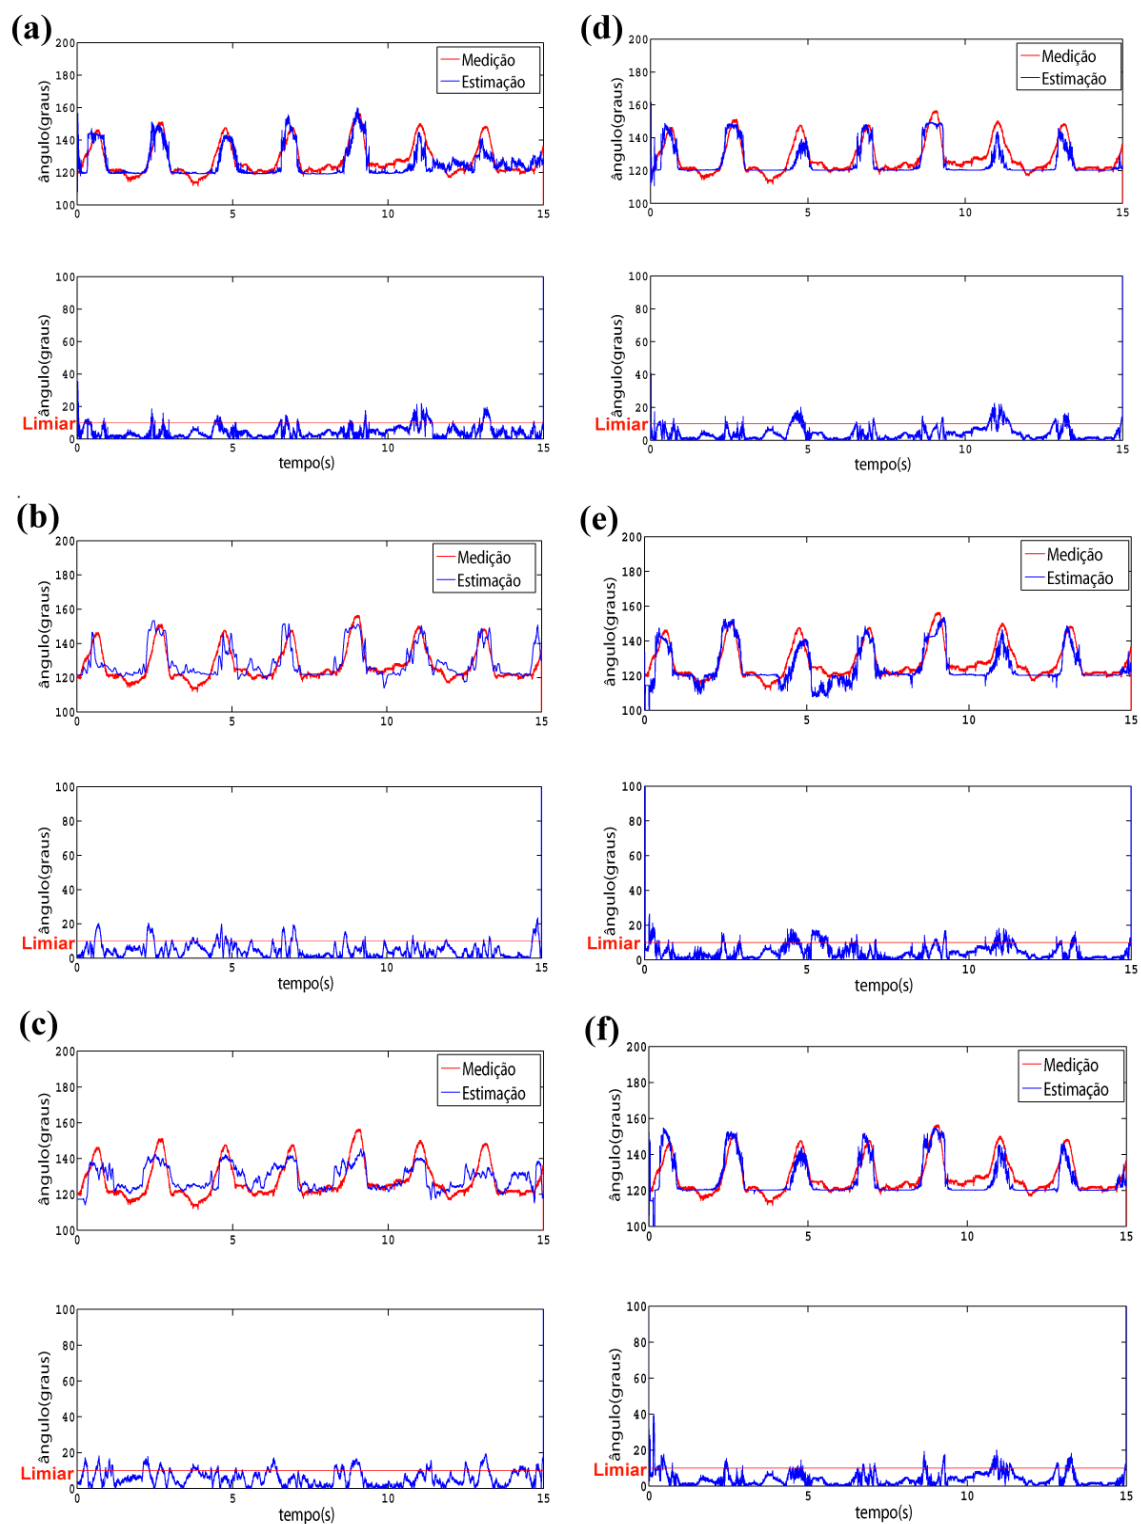


Figura 5.5 - Resultados da validação na estimação do ângulo para medição representativa de um indivíduo, em uma comparação entre: (a) algoritmo de Ferreira *et al.* (2005), (b) primeira proposta de algoritmo, (c) método EWP-PCA, (d, e, f) primeira, segunda e terceira propostas de algoritmos baseados em fusão de dados. A linha sólida (em vermelho) representa o limiar que foi utilizado para calcular as estatísticas dos eventos de erro (10 graus).

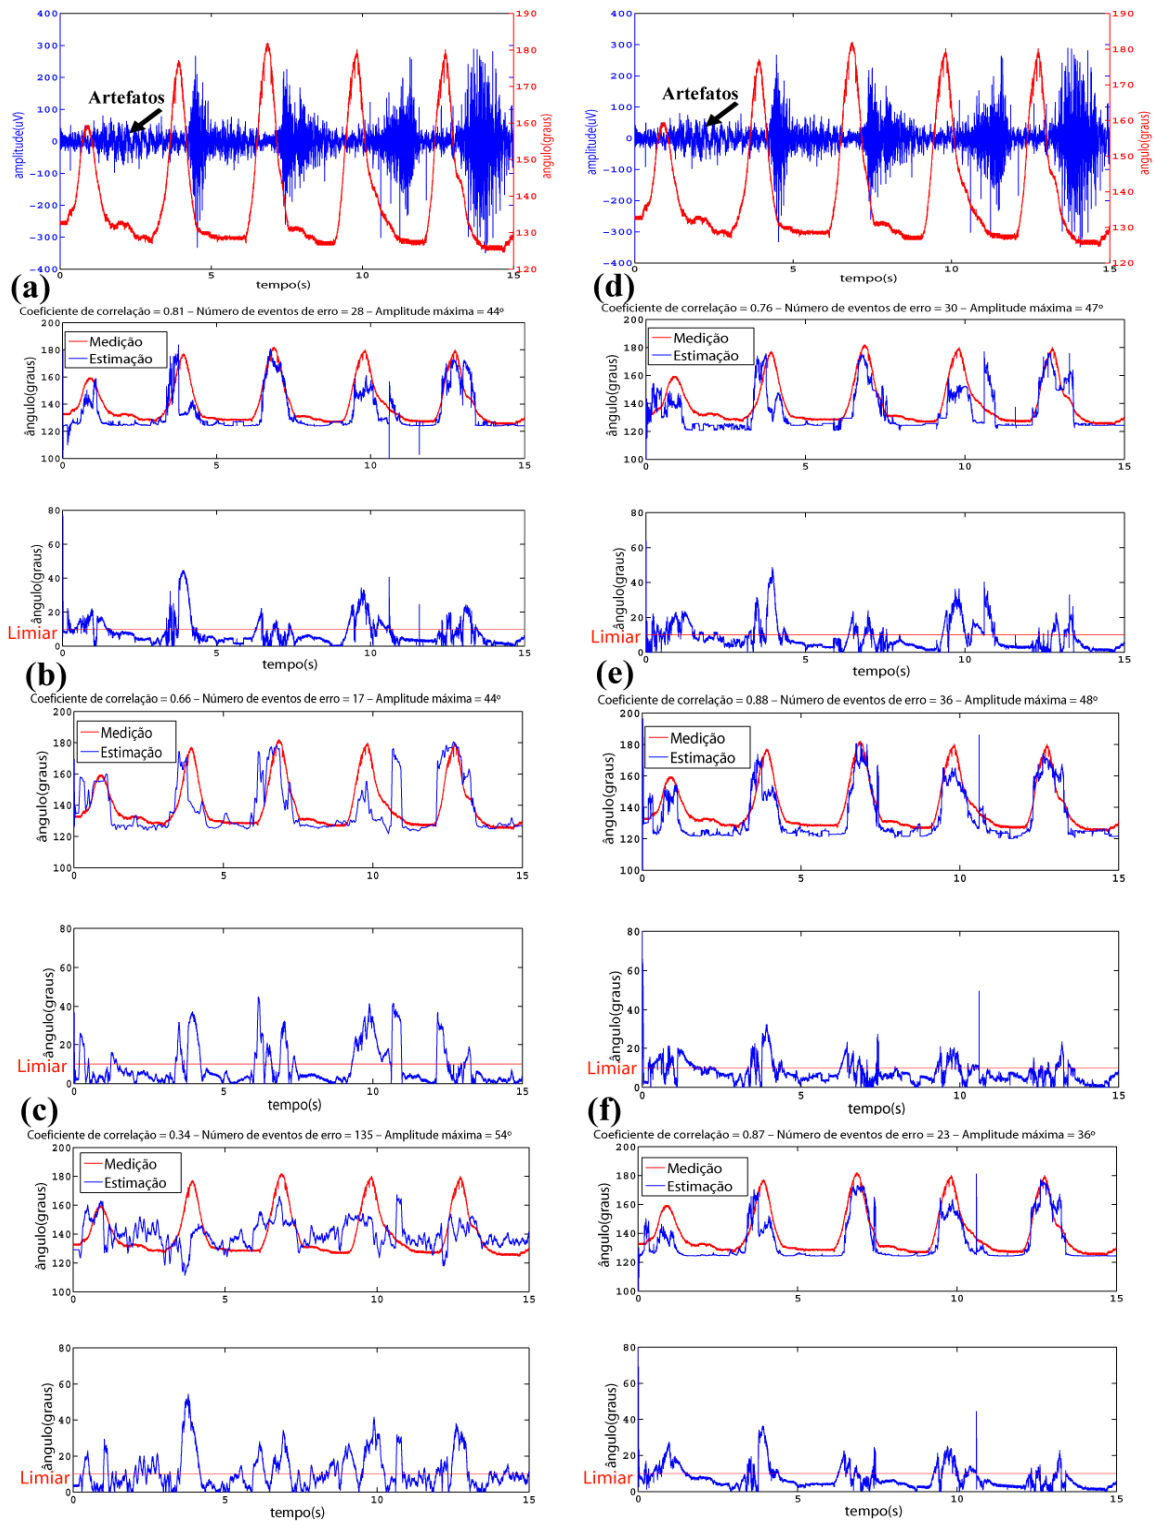


Figura 5.6 - Resultados da validação na estimação do ângulo para uma coleta de dados com presença de artefatos em um indivíduo, em uma comparação entre: (a) algoritmo de Ferreira *et al.* (2005), (b) primeira proposta de algoritmo, (c) método EWP-PCA, (d, e, f) primeira, segunda e terceira propostas de algoritmos baseados em fusão de dados. A linha sólida (em vermelho) representa o limiar que foi utilizado para calcular as estatísticas dos eventos de erro (10 graus).



Apesar da ocorrência de falsos positivos durante o processo de estimação do ângulo de deslocamento, apresentados pelos algoritmos Ferreira *et al.*, (2005), primeira proposta de algoritmo e as três variantes de algoritmos baseados em fusão de dados, o nível de degradação da estimação que as mesmas apresentam é significativamente mais baixo ao que apresenta o algoritmo EWP-PCA (Figura 5.6c). No caso da segunda e terceira variantes de fusão de dados, observar que a estimação apresenta picos que, dependendo de sua duração, poderiam ser imperceptíveis para o movimento da prótese da perna. Nestas últimas duas variantes, onde se implementa o processo de fusão entre os SMES e os sensores giroscópios no estágio de correção do filtro de *Kalman*, verifica-se um melhor comportamento ante a presença de artefatos de movimentos em relação aos demais algoritmos, resultando na obtenção de uma estimativa ótima do ângulo de deslocamento. A ocorrência de eventos de erro na primeira proposta de algoritmo durante a estimação do ângulo é menor com respeito aos outros algoritmos, justificado pelas características do mesmo de reduzir o ruído e absorver as variações (Figura 5.6b).

Outro teste que foi implementado para avaliar a robustez das propostas de algoritmos é a presença de interferência proveniente da rede elétrica. Para sua realização, foi somado, em uma coleta de dados realizada em um indivíduo (nos SMES), um sinal de 60 Hz com um nível de tensão pico de 0,1 mV. A escolha deste nível de tensão é dada pelos índices máximos de ruído da interferência de 60 Hz registrados durante os testes efetuados nos doze indivíduos. A Figura 5.7 apresenta uma comparação qualitativa nos resultados do ângulo medido, na estimativa e sua diferença absoluta para uma coleta de dados com interferência da rede elétrica no sujeito #1. Os resultados são apresentados para os algoritmos Ferreira *et al.*, (2005), primeira proposta de algoritmo, método EWP-PCA e as três variantes de algoritmos baseados em fusão de dados entre os SMES e sensores proprioceptivos. Observar que apesar da ocorrência discreta de falsos positivos (Figura 5.7 a e f), a estimação do ângulo de deslocamento pelos algoritmos mioelétricos é próxima ao ângulo medido, enfatizando-se certo nível de degradação na estimação pelo algoritmo EWP-PCA. A Tabela 5.15 apresenta as métricas estatísticas obtidas durante a implementação do teste pelos algoritmos com interferência da rede elétrica, com resultados aproximadamente equivalentes para todos os algoritmos. Porém, conclui-se que as propostas de algoritmos, fundamentalmente as variantes baseadas em fusão de dados,

apresentam um melhor comportamento ante a presença de artefatos (movimentos dos cabos e interferência da rede elétrica) em relação aos demais algoritmos; já no caso do algoritmo EWP-PCA, embora sejam em algumas métricas equivalentes seus resultados às propostas de algoritmos, seu desempenho não é comparável às mesmas.

Para a classificação em modo contínuo dos SME, tem-se demonstrado que não há vantagens no uso de métodos tempo-frequência e tempo-escala, os quais têm reportado alta exatidão na classificação em modo transiente dos SME (Englehart *et al.*, 1995; Englehart *et al.*, 2001; Wang *et al.*, 2006; Boostani e Moradi, 2003). Adicionalmente, as características tempo-frequência e tempo-escala requerem mais carga de processamento que as características no domínio do tempo, sendo que isto já foi analisado nos métodos de extração de características que se registram nos artigos relacionados ao tema (Zecca *et al.*, 2002, Oskoei e Hu, 2007). Para contrações estacionárias ou que mudam lentamente no tempo, os métodos no domínio no tempo e espectrais apresentam desempenho superior aos métodos no domínio tempo-frequência (Huang *et al.*, 2005).

A significância estatística das propostas de algoritmos com respeito ao algoritmo EWP-PCA poderia ser determinada pelo fato que a análise PCA trata de minimizar a redundância entre os vetores característicos e não considera a relação entre os mesmos e o padrão mioelétrico a ser representado no processo de classificação.

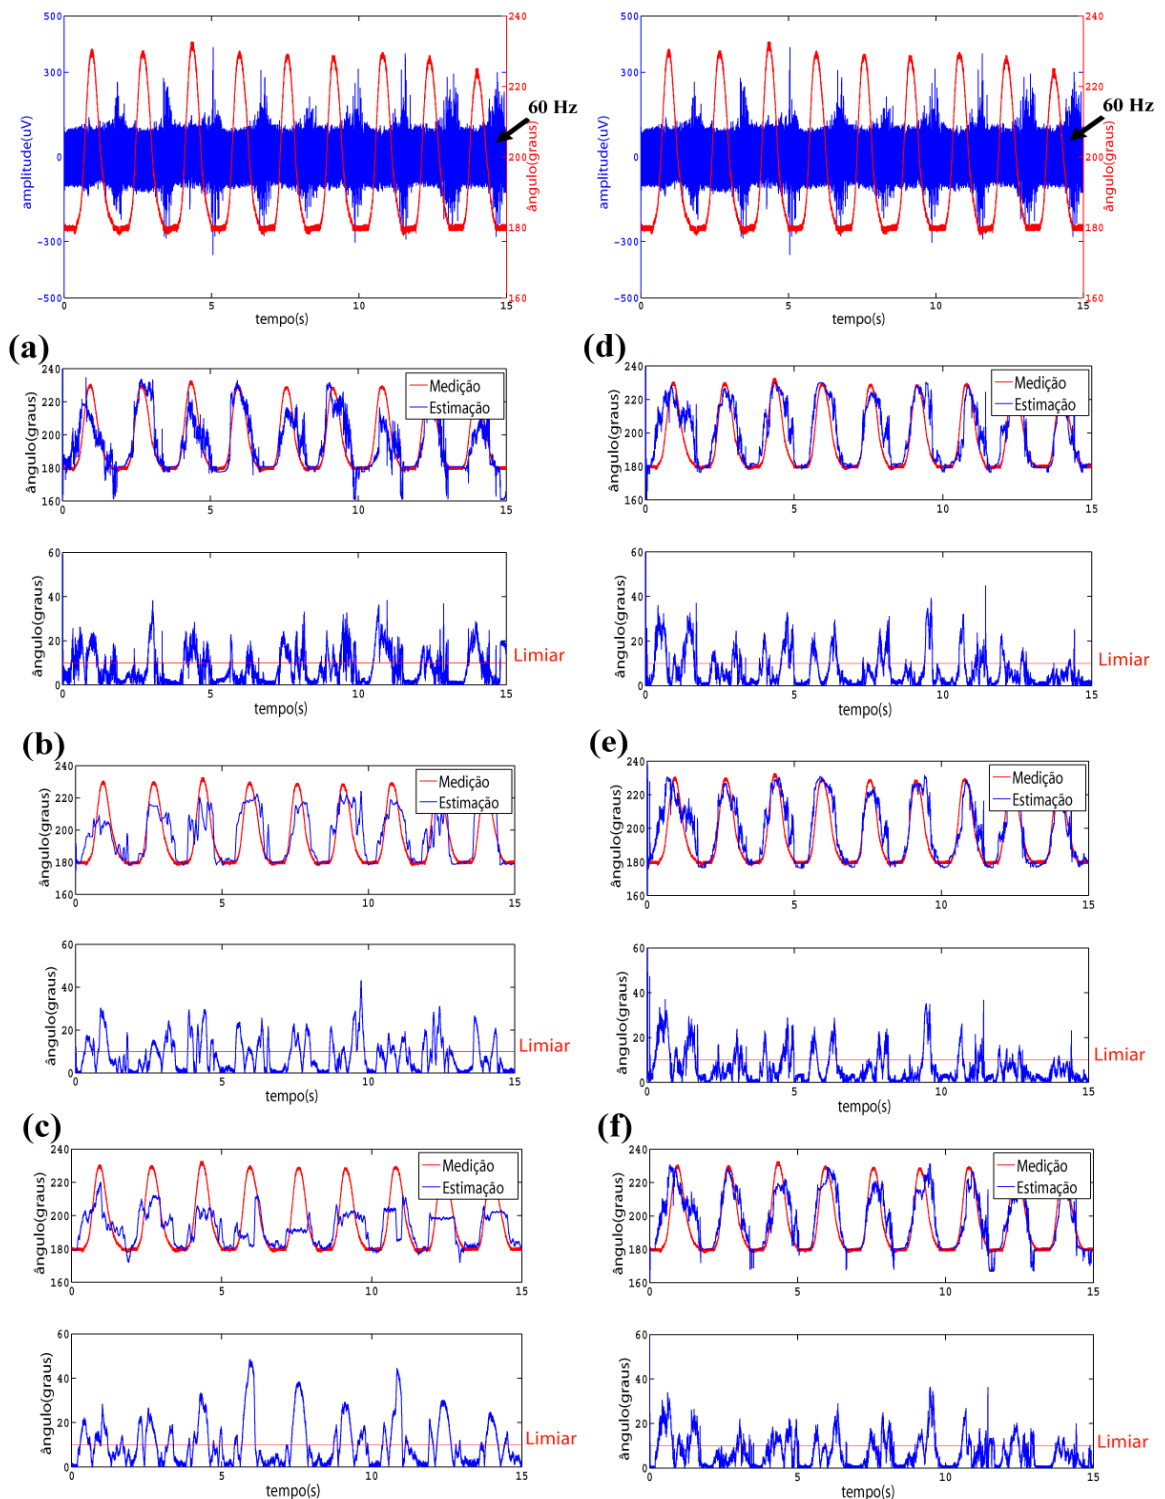


Figura 5.7 - Resultados da validação na estimação do ângulo para uma coleta de dados com presença de interferência da rede elétrica em um indivíduo, em uma comparação entre: (a) algoritmo de Ferreira *et al.* (2005), (b) primeira proposta de algoritmo, (c) método EWP-PCA, (d, e, f) primeira, segunda e terceira proposta de algoritmos baseados em fusão de dados. A linha sólida (em vermelho) representa o limiar que foi utilizado para calcular as estatísticas dos eventos de erro (10 graus).

Tabela 5.15 - Resultados das métricas estatísticas obtidas durante a implementação de teste com interferência da rede elétrica: (1) percentual erro-sinal, (2) coeficiente de correlação, (3) número de eventos de erro, (4) amplitude máxima e (5) duração máxima; em uma comparação entre: (A) primeira variante, (B) segunda variante, (C) terceira variante, (D) algoritmo Ferreira *et al.* (2005), (E) primeira proposta de algoritmo e (F) método EWP-PCA.

Métricas	Algoritmos mioelétricos					
	A	B	C	D	E	F
1	4,49%	4,98%	4,61%	5,51%	6,45%	7,47%
2	0,88	0,85	0,87	0,81	0,73	0,61
3	35	31	32	56	35	102
4	30°	40°	27°	34°	33°	48°
5	359 ms	431 ms	711 ms	680 ms	503 ms	517 ms

Embora o processo de estimação do ângulo durante o processo de validação tenha sido implementado de forma *off-line*, a seleção de duração da janela proporcional ao fator  $\lambda_k$  no método RLS e no histograma levaram em conta que o tamanho da janela e o tempo de processamento devem ser iguais ou menores que 300 ms. Adicionalmente, o comprimento da janela deve ser suficientemente grande para que se reduza a variância do espaço característico e, conseqüentemente, melhore o desempenho no processo de classificação (Asghari e Hu, 2007). Assim, estabelece-se um compromisso entre o tempo de resposta do algoritmo mioelétrico e sua exatidão. Nos estudos realizados por Englehart e Hudgins (2003), demonstra-se que para uma segmentação contínua, onde acontecem estados transientes e permanentes no sinal mioelétrico, o comprimento do segmento pode se reduzir a 128 ms ou até 32 ms, sem afetar a redução na exatidão. Confirmando este resultado e baseado no fator  $\lambda_k = 0,995$ , a duração da janela escolhida é 115 ms (para uma frequência de amostragem no processo de coleta dos dados utilizado pelo sistema de bioinstrumentação de 1744,25 Hz/canal). A mesma duração foi estabelecida para a janela do histograma, de forma tal que os dois métodos estivessem sincronizados em relação ao número de amostras (200) durante sua implementação.

## 5.5– CONCLUSÃO DO CAPÍTULO

O capítulo apresentou os resultados e a discussão da avaliação da primeira proposta de algoritmo mioelétrico baseado em SMES e da segunda proposta utilizando três variantes de algoritmos baseados em fusão de dados, através dos SMES e sensores proprioceptivos. Ambas as propostas de algoritmos foram comparadas entre si, com os algoritmos de Ferreira *et al.* (2005) e EWP-PCA. Para a comparação, foram implementadas várias métricas estatísticas em modo *off-line*: percentual erro-sinal, coeficiente de correlação, número de eventos de erro, amplitude máxima e duração máxima dos eventos de erro. As métricas foram utilizadas na avaliação do desempenho dos algoritmos na coleta de dados com medições representativas, com presença de artefatos nos movimentos dos cabos conectados aos sensores e com interferência da rede elétrica. Os resultados obtidos na comparação de ambas as propostas foram em algumas métricas, estatisticamente equivalentes e, em outras, significativas com respeito aos algoritmos Ferreira *et al.* (2005) e EWP-PCA.

## 6– CONCLUSÕES

Em contrastes aos grandes sucessos na decodificação de movimentos discretos, tais como a flexão e extensão dos membros individuais da mão, a predição dos ângulos da articulação através do SMES ainda é um processo em desenvolvimento (Yoshikawa *et al.*, 2007; Varol e Goldfarb, 2007; Smith *et al.*, 2008; Au *et al.*, 2008; Shrirao *et al.*, 2009; Smith *et al.*, 2009). É importante estimar continuamente os ângulos das articulações do indivíduo para obter uma interface humana mais natural e intuitiva. A primeira proposta de algoritmo foi concebida como uma alternativa ao método proposto por Ferreira *et al.* (2005), que consiste em usar modelos auto-regressivos para extração de características, e uma rede perceptron multicamada como estágio de classificação de padrões. O método proposto introduz melhorias no processo de extração de características através de uma combinação de métodos no domínio espectral e temporal – coeficientes auto-regressivos e histograma na amplitude do sinal. Adicionalmente, incorpora-se um estágio de projeção de características usando mapas auto-organizáveis com o objetivo de reduzir a dimensionalidade dos dados na entrada do classificador de padrões mioelétricos.

Durante o processo de revisão bibliográfica do tema da pesquisa relacionado à segunda proposta de algoritmo, não foi encontrado abundante uso de fusão de dados com os SMEs. Até o ano 2009, encontrou-se apenas o trabalho de López *et al.* (2009), que mantém como ponto comum com respeito a esta proposta o uso do filtro de *Kalman* para a implementação da estimação de algumas das variáveis que compõem o algoritmo. Salvo esta exceção, não se encontrou nenhum outro método relacionado à estimação contínua do ângulo de articulação, que propusesse uma arquitetura de algoritmo mioelétrico com a fusão de dados, como a proposta do segundo algoritmo, onde se mesclam estágios de extração e classificação de padrões mioelétricos com filtro de *Kalman*, para a estimação e correção do ângulo do joelho.

Durante a idealização dos algoritmos mioelétricos, foi preciso conceber uma plataforma de bioinstrumentação experimental. A plataforma foi projetada de maneira a permitir coletar, além dos sinais mioelétricos, variáveis de propriocepção relacionadas ao deslocamento e à velocidade angular do joelho. A informação sobre o deslocamento é

utilizada durante o processo de treinamento da arquitetura de redes neurais que compõem os algoritmos propostos, e a informação sobre a velocidade para efetuar correções da estimativa angular através do filtro de *Kalman*. Assim, foi desenvolvido um software, com uma interface visual, que permite realizar a coleta de dados e estabelecer um protocolo de transferência entre o sistema de bioinstrumentação e o computador. O software gera um par de arquivos de treino e validação que são pós-processados pelos algoritmos mioelétricos propostos. É requisito fundamental para a projeção do sistema de bioinstrumentação dentro da prótese de perna: a redução da escala de integração dos componentes com vistas à miniaturização do sistema, a portabilidade do sistema através do uso de bateria e a utilização de protocolos de transmissão *wireless* quando se efetuarem os processos de treinamento da prótese, através do computador.

Dois protocolos experimentais com quatro e doze indivíduos saudáveis, respectivamente, foram propostos. Nos experimentos, cada sujeito efetua um processo de marcha durante um tempo determinado, com direção e velocidade constantes. Durante cada medição, foi estabelecido um período de repouso, e a velocidade de marcha pôde ser modificada. O conjunto dos sinais mioelétricos e proprioceptivos foram divididos em treinamento e validação que, posteriormente, são empregados na avaliação dos algoritmos mioelétricos. Neste primeiro estágio da implementação dos protocolos clínicos em indivíduos saudáveis, não se objetivou, os testes com fadiga. Isto se deve aos protocolos avaliarem a possibilidade da predição do ângulo do joelho a partir das informações coletadas, seguindo requerimentos estabelecidos (SENIAM, 2008). Nos testes de fadiga, os padrões dos sinais empregados na realização do treinamento diferem dos padrões correntes depois de um período, e conseqüentemente, a exatidão na classificação diminui notavelmente. Os cabos de conexão dos eletrodos à pele devem seguir as recomendações do SENIAM (2008), para reduzir a indução das fontes de ruído radiadas e eletromagnética, no sistema de bioinstrumentação.

A primeira proposta de algoritmo é constituída de três estágios. No primeiro foram utilizados métodos no domínio do tempo (histograma) e da frequência (mínimos quadrados recursivos). O segundo estágio tem como função reduzir o espaço característico por meio de mapas auto-organizáveis. Isso possibilita um incremento no número de

sensores de SMES sem aumentar a complexidade da rede neural. O último estágio realiza a estimação do ângulo do joelho por meio de uma rede perceptron multicamada.

Na segunda proposta, é implementado um estágio de extração de características utilizando métodos no domínio do tempo (entropia do SME) e da frequência (coeficientes cepstrais). O segundo estágio tem como função estimar o ângulo de deslocamento por meio de uma rede perceptron multicamada. O último estágio realiza a fusão de dados através do filtro de *Kalman*, utilizando três variantes. Na primeira variante a estimativa da velocidade angular obtida pelo filtro é fusionada através da rede perceptron multicamada para obter uma estimativa do ângulo do joelho. Na segunda variante a estimativa do ângulo do joelho resultante da rede perceptron multicamada é fusionada no processo de correção do filtro de *Kalman* com a informação de velocidade angular. A terceira variante envolve um detector de teste de compatibilidade entre os processos de predição e correção do filtro de *Kalman*. Com esse detector, inconsistências provenientes da rede neural são filtradas pelo algoritmo. As variantes de fusão de dados possibilitarão aumentar a robustez do algoritmo durante a estimativa do ângulo, na presença de artefatos e ruído nos sinais mioelétricos.

Com os dados obtidos a partir dos protocolos experimentais, foi possível comparar (em modo *off-line*), o desempenho dos algoritmos propostos com o método de Ferreira *et al.* (2005), que utiliza mínimos quadrados recursivos no estágio de extração de características e redes perceptron multicamada para a classificação dos padrões mioelétricos. Outra comparação foi realizada utilizando *wavelet packets* – análise de componentes principais (Wang *et al.*, 2006). Neste método, a energia dos coeficientes da *wavelet* é utilizada para classificar os sinais mioelétricos. A análise de componentes principais é, então, aplicada aos vetores resultantes, com o objetivo de reduzir sua dimensionalidade. Para a avaliação foram usados indicadores quantitativos, como percentual erro–sinal, coeficiente de correlação, número de eventos de erro, amplitude máxima dos eventos de erro e duração máxima dos mesmos. O desempenho da primeira proposta do algoritmo apresenta resultados equivalentes com respeito ao método proposto por Ferreira *et al.* (2005) em quase todos os indicadores, com exceção do número de eventos de erros, onde o resultado foi significativamente menor. Na comparação com respeito ao método proposto por Wang *et al.* (2006), a primeira proposta apresenta



resultados significativos de número e amplitude máxima de eventos de erro. Na segunda proposta de algoritmo mioelétrico baseada em fusão de dados, a primeira variante de fusão de dados apresenta significativamente menor amplitude máxima de eventos de erro com respeito aos métodos Ferreira *et al.* (2005) e a primeira proposta de algoritmo. Na comparação com respeito ao método Wang *et al.* (2006), os resultados são significativos em quase todos os indicadores com exceção da duração máxima de eventos de erros. A segunda variante apresenta resultados equivalentes em todas as métricas estatísticas com respeito aos métodos Ferreira *et al.* (2005) e a primeira proposta de algoritmo, e significativamente maior coeficiente de correlação e menor número de eventos de erros com respeito ao método Wang *et al.* (2006). A terceira variante apresenta um desempenho similar à variante de algoritmo anterior na comparação com os métodos Ferreira *et al.* (2005), primeira proposta de algoritmo e Wang *et al.* (2006). Conclui-se que as propostas de algoritmos, fundamentalmente as variantes baseadas em fusão de dados, apresentam um melhor comportamento ante a presença de artefatos (movimentos dos cabos e interferência da rede elétrica) em relação aos demais algoritmos; já no caso do algoritmo EWP-PCA, embora sejam em algumas métricas equivalentes seus resultados às propostas de algoritmos, seu desempenho não é comparável às mesmas.

A primeira proposta de algoritmo fornece a redução de dimensionalidade que possibilita a conexão de um maior número de sensores SMES sem afetar consideravelmente o desempenho da rede perceptron multicamada. Neste contexto recomenda-se sua utilização em relação à segunda proposta de algoritmo.

A segunda proposta de algoritmo com seus três variantes possibilitam a integração de sensores de diversas naturezas, além dos SMES, pelo processo de fusão de dados através do filtro de *Kalman*. Espera-se que, quanto maior o número de informação fornecido pelos algoritmos mioelétricos no processo de estimação do ângulo de deslocamento, melhor será a precisão e robustez obtida para o controle da prótese. O algoritmo apresenta um desempenho satisfatório na presença de ruído de medição e artefatos, no trabalho com a prótese de perna. Mas, sua implementação envolve um grau maior de complexidade na obtenção dos coeficientes cepstrais através dos coeficientes AR com relação à primeira proposta de algoritmo. Com o aumento do número de sensores

SMEs na entrada do algoritmo mioelétrico problemas ocorrer quanto ao tempo de convergência na rede perceptron multicamada e conseqüentemente, isto afetaria o tempo de resposta no controle mioelétrico. Conclui-se assim, a recomendação para sua implementação em modo *on-line* da primeira proposta de algoritmo quando o número de sensores for grande e o microprocessador não tiver capacidade para seu processamento. Entretanto, considerando o aspecto de robustez a artefatos, a segunda variante de algoritmo mioelétrico baseado em fusão de dados é o mais indicado.

O trabalho de tese permitiu a conformação de vários indicadores quantitativos associados à detecção dos eventos de erro na estimação contínua do ângulo em modo *off-line* (número, amplitude máxima e duração máxima de eventos de erro) que possibilitaram avaliar o desempenho dos algoritmos mioelétricos e que poderiam ser aplicáveis com modificações à estimação de movimentos discretos.

O trabalho de tese apresentado representa a primeira fase de vários estágios que conformam o desenvolvimento de uma prótese robótica de perna. Concluiu-se que os resultados obtidos, quanto às propostas de algoritmos, foram satisfatórios nos testes implementados em modo *off-line* e recomenda-se sua inclusão no desenvolvimento da prótese e a implementação dos testes em modo *on-line* em interface com o bloco de controle do joelho. O trabalho apresenta as seguintes contribuições na temática orientada ao desenvolvimento de algoritmos mioelétricos para o controle de prótese:

1. Desenvolvimento e avaliação de uma proposta de algoritmo para a estimação contínua do ângulo de deslocamento do joelho, baseado em sinais mioelétricos de superfície, com a utilização de mescla de métodos no domínio da frequência e no domínio do tempo no estágio de extração de características, e utilização de redes neurais em cascada para a classificação dos padrões mioelétricos.
2. Desenvolvimento e avaliação de uma proposta de algoritmo para a estimação contínua do ângulo de deslocamento do joelho através de três variantes de algoritmos, baseadas em sinais mioelétricos e sensores proprioceptivos, com a utilização de mescla de métodos no domínio da frequência e no domínio do tempo no estágio de extração de características, utilização de redes neurais para o processo de classificação dos padrões

mioelétricos e fusão da estimativa do ângulo a partir da rede neural com a informação dos sensores proprioceptivos através do filtro de *Kalman*.

Espera-se que as propostas dos algoritmos sejam utilizados em indivíduos amputados com prótese em membros inferiores nos próximos estágios e que possam levar a uma posterior implementação em tempo real com sua integração na prótese. Na continuação do desenvolvimento são esperadas limitações de peso e de velocidade de locomoção, baseadas nas respostas dos atuadores. A movimentação em escadas apresenta algumas limitações relacionadas ao posicionamento do pé no degrau, em condições onde o contato do pé com o solo for parcial, levando a um grande esforço dos atuadores e conseqüente saturação.

Os algoritmos propostos poderiam ser utilizados para outras aplicações, tais como, para a medida contínua de movimento, aplicados a campos de neuro-reabilitação e em trabalhos com prótese de exoesqueletos.

## REFERÊNCIAS BIBLIOGRÁFICAS

- Ahlstrom, M. L. e Tompkins, W.J. (1985). "Digital filters for real-time ECG signal processing using microprocessor". In: *IEEE Trans. Biomed. Eng.*, (32), 708-713.
- Ajiboye, A.B. e Weir, R. F. ff. (2005). "A heuristic fuzzy logic approach to EMG pattern recognition for multifunctional prosthesis control". In: *IEEE Trans. Neural Syst. Rehabil. Eng.*, (13)3, 280-291.
- Au, A.T.C. e Kirsch, R.F. (2000). "EMG-based prediction of shoulder and elbow kinematics in able-bodied and spinal cord injured individuals". In: *IEEE Trans. Rehabil. Eng.*, (8)4, 471-480.
- Au, S., Berniker, M. e Herr, H. (2008). "Powered ankle-foot prosthesis to assist level-ground and stair-descent gaits". In: *Journal of Neural Networks*, (21), 654-666.
- Basmajian, J.V. e DeLuca, C.J. (1985). *Muscle Alive: Their Functions Revealed by Electromyography*, 5(ed.) Baltimore, Williams & Wilkins, 561p.
- Battiti, R. (1992). "First and second order methods for learning: Between steepest decent and Newton's method". In: *Neural Computation*, (4)2, 141-166.
- Beltramini, L. M. (1999). "Elementos de Histologia e Anotomo-fisiologia Humana". [capturado:21/07/2009], <http://biologia.ifqsc.sc.usp.br/cap5/MUSCULAR.html>
- Boostani, R. e Moradi, MH. (2003). "Evaluation of the forearm EMG signal features for the control of a prosthetic hand". In: *Physiological Measurement*, (24), 309-319.
- Bottomley, A. H. (1955). "Myoelectric control of powered prosthesis". In: *J. Bone Joint Surg.*, 37, 506p.
- Castellini, C. e Smagt, P. van der (2009). "Surface EMG in advanced hand prosthetics". In: *Biological Cybernetic*, 100, 35-47.
- Campbell, J. (1997). "Speaker recognition: A tutorial". In: *Proceedings of the IEEE*, 85(9), 1437-1462.
- Charalambous, C. (1992). "Conjugate gradient algorithm for efficient training of artificial neural networks". In: *IEEE Proceedings*, (139)3, 301-310.
- Chan, A.D.C. e Englehart, K. (2003). "Continuous classification of myoelectric signals for powered prostheses using Gaussian mixture models". In: *Proceedings of 25th Annual International Conference of the Engineering in Medicine and Biology Society*.

- Chan, A.D.C. e Green, G. C. (2007). “Myoelectric control development toolbox”. In: *Proceedings of the 30<sup>th</sup> Annual International IEEE EMBS Conference*.
- Chen, X., Zhu, X. e Zhang, D. (2009). “Use of the discriminant Fourier-derived cepstrum with feature-level post-processing for surface electromyographic signal classification”. In: *Physiological Measurement*, (30), 1399-1413.
- Chiou, Y., Luh, J., Chen, S., Lai, J. e Kuo, T. (2004). “The comparison of electromyographic pattern classifications with active and passive electrodes”. In: *Medical Engineering and Physics*, (26)7, 605-610.
- Chu, J., Moon, I., Kim, S. e Mun, M. (2005). “Control of multifunction myoelectric hand using a real time EMG pattern recognition”. In: *International Conf. on Intelligent Robots and Systems IEEE/RSJ-IROS*, 3957-3962.
- Clancy, E. A., Morin, E. L. e Merletti, R. (2002). “Sampling, noise-reduction and amplitude estimation issues in surface electromyography”. In: *Journal Electromyography and Kinesiology*, 12, 1-16.
- Corts, C. e Vapnik, V. (1995). “Support vector networks”. In: *Mach. Learn.*, (20), 273-297.
- Constantin, V. A. (1995). Fuzzy logic and NeuroFuzzy applications explained. In: Prentice-Hall, Inc: Upper Saddle River, NJ.
- Cram, J. R. e Kasman, G. (1998). Introduction to Surface Electromyography. In: Aspen.
- Dasarathy, B. V. (1997). “Sensor fusion potential exploitation-innovative architectures and illustrative applications “. In *IEEE Proceedings*, (85), 24-38.
- Delsys Inc. (1996).Tutorials &Whitepapers: ”A discussion on Surface Electromyography: Detection and recording”, [capturado:21/03/2000], <http://www.delsys.com/library/tutorials.htm>
- Delsys Inc. (2003).Tutorials & Whitepapers: ”Fundamental Concepts in EMG Signal Acquisition”,[capturado:21/04/2007],<http://www.delsys.com/library/tutorials.htm>
- DeLuca, C. J. (1979). “Physiology and Mathematics of Myoelectric Signals”. In: *IEEE Trans. Biomedical Eng.*, 26(6), 313-325.
- DeLuca, C. J. e Knaflitz, M. (1992). Surface Electromyography: What’s New?
- DeLuca, C. J. (2006). “Electromyography”. In: *Encyclopedia of Medical Devices and Instruments*, 98-109.

- Delis, A. L., da Rocha, A. F., dos Santos, I., Sene Jr, I. G., Salomoni, S. e Borges, G. A. (2008). “Development of a Microcontrolled Bioinstrumentation System for Active Control of Leg Prostheses”. In: *Proceedings of the 30<sup>th</sup> Annual International IEEE EMBS Conference*, 2393-2396.
- Delis, A. L., Carvalho, J. L., da Rocha, A. F., Nascimento, F. A. O. e Borges, G. A. (2009). “Development of a Myoelectric Controller Based on Knee Angle Estimation”. In: *Proceedings of the Second International Conference on Biomedical Electronics and Devices*, 97-103.
- Delis, A. L., Carvalho, J. L., Rodríguez, S. S., Borges, G. A., dos Santos, I. e da Rocha, A. F. (2009). “Fusion of Electromyographic Signals with Proprioceptive Sensor Data in Myoelectric Pattern Recognition for Control of Active Transfemoral Leg Prostheses”. In: *Proceedings of the 31<sup>st</sup> Annual International IEEE EMBS Conference*, 4755-4758.
- Delis, A. L., Carvalho, J. L., da Rocha, A. F., Ferreira, R. U., Rodrigues, S. S e Borges, G. A. (2009). “Estimation of the knee joint angle from surface electromyographic signals for active control of leg prostheses”. In: *Physiological Measurement*, (30), 931-946.
- Delis, A. L., Carvalho, J. L., Seisdedos, C. V., Borges, G. A., e da Rocha, A. F. (2010).” Myoelectric Control Algorithms for Leg Prostheses Based on Data Fusion with Proprioceptive Sensors”. In: *Proceedings ISSNIP Biosignals and Biorobotics Conference 2010*, 137-142.
- De Maesschalck, R., Jouan-Rimbaud, D., Massart, D.L. (2000). “The Mahalanobis distance”. In: *Chemometrics and Intelligent Laboratory Systems*, 50, 1-18.
- De Toledo, C. M. (2008). Desenvolvimento de software de apoio para a aquisição e caracterização de dados eletromiográficos. Trabalho de Graduação em Engenharia Elétrica. Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília.
- Diniz, P. S. R. (2008). Adaptive Filtering Algorithms and Practical Implementation. In: Springer Science+Business Media, LLC.
- Dietl, H. e Bargehr, H. (1997). “The application of electronics in prosthetics for lower extremities”. In: *Med. Orthop. Tech.*, (117), 31-35.
- Dorcas, D. S., e Scott, R. N. (1966). “A three - state myoelectric control”. In: *Med. Biol. Eng.*, 4, 367p.

- Doershuk, P. C., Gustafson, D. E. e Willsky, A. S. (1983). "Upper extremity limb function recognition using EMG signal analysis". In: *IEEE Trans. Biomedical Eng.*, (30), 18-29.
- Duda, R. O., Hart, P. E. e Stork, D. G. (2000). *Pattern Classification*. In: New York: Wiley, 2nd edn.
- Englehart, K., Hudgins, B., Stevenson, M. e Parker, P. A. (1995). "Classification of transient myoelectric signals using dynamic feedforward neural network". In: *Proceedings World Congress Neural Networks*.
- Englehart, K., Hudgins, B., Parker, P. A. e Stevenson, M. (1999). "Classification of the myoelectric signal using time-frequency based representation". In: *Med. Eng. Phys.*, (21), 431-438.
- Englehart, K., Hudgins, B. e Parker, P. A. (2001). "A wavelet-based continuous classification scheme for multifunction myoelectric control". In: *IEEE Trans. Biomedical Eng.*, (48)3, 302-310.
- Englehart, K. e Hudgins, B. (2003). "A robust, real-time control scheme for multifunction myoelectric control". In: *IEEE Trans. Biomedical Eng.*, (50)7, 848-854.
- Enoka, R. M. (1994). *Neuromechanical Basic of Kinesiology*. In: *Human Kinetics*.
- Farfán, D. F., Politti, C. J., e Felice, J. C. "Evaluación de Patrones Temporales y Espectrales para el Control Mieléctrico". In: *XV Congreso Argentino de Bioingeniería: 095BM*.
- Fakuda, O., Tsuji, T., Kaneko, M. e Otsuka, A. (2003). "A human-assisting manipulator teleoperated by EMG signals and arm motions". In: *IEEE Trans. Robot. Autom.*, (19)2, 210-222.
- Farina, D. e Merletti, R. (2000). "Comparison of algorithms for estimation of EMG variables during voluntary isometric contractions". In: *Journal Electromyography and Kinesiology*, 10, 337-349.
- Ferreira, R. U., da Rocha, A. F., Casão, Jr. C. A., Borges, G, A., Nascimento, F. A. O. e Veneziano, W. H. (2005). "Reconhecimento de Padrões de Sinais de EMG para Controle de Prótese de Perna". In: *Proceedings of the XI Congresso Brasileiro de Biomecânica*.
- Ferguson, S., e Dunlop, G. R. (2002). "Grasp Recognition from Myoelectric Signals". In: *Proceedings Australian Conference on Robotics and Automation*, 83-87.

- Gao, J. B. e Harris, C. J. (2002). "Some remarks on Kalman filters for the multisensor fusion". In: *Information Fusion*, (3), 191-201.
- Graupe, D. e Cline, W. K. (1975). "Functional Separation of EMG Signals via ARMA Identification Methods for Prosthesis Control Purpose". In: *IEEE Transactions on Systems, Man and Cybernetic*, (5)2, 252-259.
- Guang-ying, Y. e Zhi-zeng, L. (2004). "Surface Electromyography Disposal Based on the Method of Wavelet De-noising and Power Spectrum". In: *Proceedings of the 2004 International Conference on Intelligent Mechatronics and Automation*, 896-900.
- Guyton, A.C. (1988). *Fisiologia Humana*. 6(ed.) Rio de Janeiro, Guanabara Koogan S.A., 564p.
- Hall, D. L. e Llinas, J. (1997). "An introduction to multisensor data fusion". In *IEEE Proceedings*, (85), 6-23.
- Hamilton, J.D. (1994). *Time Series Analysis*, Inc: Princeton University Press.
- Hamilton, P. S. (1996). "A Comparison of Adaptive and Nonadaptive Filters for Reduction of Power Line Interference in the ECG". In: *IEEE Trans. Biomed. Eng.*, (43).
- Hang-Pang, H. e Chun-Yen, Ch. (1999). "Development of a Myoelectric Discrimination System for a Multi-Degree Prosthetic Hand". In: *Proceedings of the 1999 IEEE International Conference on Robotic & Automation*, 2392-2397.
- Han-Pang, H., Yi-Hung, L. e Chun-Shin, W. (2003). "Automatic EMG Feature Evaluation for Controlling a Prosthetic Hand Using a Supervised Feature Mining Method: An Intelligent Approach". In: *Proceedings of the 2003 IEEE International Conference on Robotics & Automation*, 220-225.
- Hagan, M. T. e Menhaj, M. B. (1994). "Training feedforward networks with the Marquardt Algorithm". In: *IEEE Trans. Neural Net.*, (5)6, 989-993.
- Hargrove, L. J., Englehart, K. e Bernard, H. (2008). "A training strategy to reduce classification degradation due to electrode displacements in pattern recognition based myoelectric control". In: *Biomedical Signal Processing and Control*, (3), 175-180.
- Hargrove, L. J., Li, G., Englehart, K. B. e Hudgins, B. S. (2009). "Principal Components Analysis Preprocessing for Improved Classification Accuracies in Pattern-Recognition-Based Myoelectric Control". In: *IEEE Trans. Biomedical Eng.*, (56)5, 848-854.



- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. New Jersey: Prentice Hall.
- Herberts, P. (1969). "Myoelectric signal in control of prostheses". In: *Acta Orthop Scand (suppl.)*, 40, 124p.
- Hefftner, G., Zucchini, W. e Jaros, G. G. (1988). "The Electromyogram (EMG) as a Control Signal for Functional Neuromuscular Stimulation-Part I: Autoregressive Modeling as a Means of EMG Signature Discrimination". In: *IEEE Trans. Biomedical Eng.*, (35)4, 230-237.
- Huang, J. Z., Ng, M. K., Rong, H., e Li., Z. (2005). "Automated variable weighting in k-means type clustering". In: *IEEE Transactions on Pattern Analysis and Machine Intelligence*, (27)5, 657-668.
- Huang, Y., Englehart, K. B., Hudgins, B. e Chan, A. D. C. (2005). "A Gaussian mixture model based classification scheme for myoelectric control of powered upper limb prostheses". In: *IEEE Trans. Biomedical Eng.*, (52)11, 1801-1811.
- Hudgins, B., Parker, P. A. e Scott, R. N. (1993). "A new strategy for multifunction myoelectric control". In: *IEEE Trans. Biomedical Eng.*, (40)1, 82-94.
- Hussain, M. S., Reaz, M. B. I., Mohd-Yasin, F. e Ibrahimy M. I. (2009). "Electromyography signal analysis using wavelet transform and higher order statistics to determine muscle contraction". In: *Expert System*, (26)1, 35-48.
- Hussein, S. E. e Granat, M. H. (2002). "Intention detection using a neuro-fuzzy EMG classifiers ". In: *IEEE Eng. Med. Biol.*, 123-129.
- Instituto Brasileiro de Geografia e Estatística-IBGE (2000). Censo demográfico, características gerais da população.
- Ifeachor, E. C. e Jervis, B. W. (1993). "Digital Signal Processing: A Practical Approach". In: *Adaptive Digital Filters*. Wokingham, England, Addison-Wesley, 541-576.
- Ito, K., Tsukamoto, M. e Kondo, T. (2008). "Discrimination of Intended Movements based on Nonstationary EMG for A Prosthetic Hand Control". In: *Proceedings the ISCCSP*, 14-19.
- Kastner, J., Nimmervoll, R. e Wagner, I. P. (1999). "What are the benefits of the Otto Bock C-leg? A comparative gait analysis of C-leg, 3R45 and 3R80". In: *Med. Orthop. Tech.*, (119), 131-137.

- Kato, I., et al. (1969). "Multifunctional myoelectric hand prosthesis with pressure sensory feedback system – WASEDA Hand – 4P". In: *Proc 3<sup>rd</sup> Int Symp External Control of Human Extremities*, Dubrovnik, Yugoslavia, 155-170.
- Kang, W. J., Shiu, J. R., Cheng, Ch. K., Lai, J. S., Tsao, H. W. e Kuo, T. S. (1995). "The Application of Cepstral Coefficients and Maximum Likelihood Method in EMG Pattern Recognition". In: *IEEE Trans. Biomedical Eng.*, (42)8, 777-785.
- Karlsson, S., Yu, J. e Akay, M. (1999). "Enhancement of spectral analysis of myoelectric signals during static contractions using wavelet methods". In: *IEEE Trans. Biomed. Eng.*, (6)46, 123-129.
- Karlik, B., Tokhi, M. O. e Alci, M. (2003). "A fuzzy clustering neural network architecture for multifunction upper-limb prosthesis". In: *IEEE Trans. Biomed. Eng.*, (50)11, 1255-1261.
- Karlsson, S., Jun, Y., e Akay, M. (2000). "Time-frequency analysis of myoelectric signals during dynamic contractions: a comparative study". In: *IEEE Trans. Biomedical Eng.*, (47) 2, 228-238.
- Khushaba, R. N., Al-Jumaily, A. e Al-ni, A. (2009). "Evolutionary fuzzy discriminant analysis feature projection technique in myoelectric control". In: *Pattern Recognition Letters*, 30, 699-707.
- Kobrinski, A. E. et al. (1960). "Problems of Bioelectric Control". In: *J. F. Coles, ed., Automatic and remote control, Proc 1st IFAC Int Conf*, (2), Butterworths, London.
- Kollias, S. e Anastassiou, D. (1989). "An adaptive least squares algorithm for the efficient training of artificial neural networks". In: *IEEE Trans. Circ. Syst.*, (36)8, 1092-1101.
- Kohonen, T. (2001). *Self-Organizing Maps*. In: New York: Springer, 3rd edn.
- Konrad, P. (2005). *The ABC of EMG – A Practical Introduction to Kinesiological Electromyography*. In: Noraxon, Inc.
- Leis, A. A., e Trapani, V. C., (2000). *Atlas of Electromyography*. In: Oxford University Press.
- Liu, H., Chen, X. e Chen, Y. (2005). "Wavelet transform and real-time learning method for myoelectric signal in motion discrimination". In: *7<sup>th</sup> International Symposium on Measurement Technology and Intelligent Instruments*, 250-253.

- Liu, Y., Huang, H. e Weng, Ch. (2007). "Recognition of Electromyographic Signals Using Cascaded Kernel Learning Machine". In: *IEEE/ASME Trans. on Mechatronics*, (12)3, 253-264.
- Liu, H. Y. e Chen, Y. T. (2007). "Face recognition using total margin-based adaptive fuzzy support vector machines". In: *IEEE Trans. Neural Network*, (18)1, 178-192.
- Ljung, L. (1987). *Linear System Identification*. In: Prentice-Hall, Inc: Englewood Cliffs.
- López, N. M., di Sciascio, F., Soria, C. M. e Valentinuzzi, M. E. (2009). "Robust EMG sensing system based on data fusion for myoelectric control of a robotic arm". In: *Biomedical Engineering OnLine*, (8)5.
- Lucas, M.-F., Gaufriau, A., Pascual, S., Doncarli, Ch., e Farina, D. (2007). "Multi-channel surface EMG classification using support vector machines and signal-based wavelet optimization". In: *Biomedical Signal Processing and Control*, BSPC-73.
- Luo, R. C., Yih, Ch. e Su, K. L. (2002). "Multisensor Fusion and Integration: Approaches, Applications, and Future Research Directions". In: *IEEE Sensors*, (2)2, 107-119.
- Maitrot, A., Lucas, M. F., Doncarli, C. e Farina, D. (2005). "Signal-dependent wavelets for electromyogram classification". In: *Med. Biol. Eng. Computing*, (43), 487-492.
- Mann, R. W. (1981). "Cybernetic limb prosthesis: The ALZA distinguished lecture". In: *A Biomed Eng*, 9, 1-43.
- Manyika, J. e Durrant-Whyte, H. (1994). *Data Fusion and Sensor Management: A Decentralized Information — Theoretic Approach*. In: Ellis Horwood, London.
- Merlo, A., Farina, D. e Merletti, R. (2003). "A fast and reliable technique for muscle activity detection from surface EMG signals". In: *IEEE Trans. Biomedical. Eng.*, 50(3), 316-323.
- Merletti, R., e Parker, P. (2004). *Electromyography Physiology, Engineering and Noninvasive Applications*. IEEE Press Engineering in Medicine and Biology Society.
- Monaghan, C. C., Van Riel, W. J. B. M. e Veltink, P. H. (2009). "Control of triceps surae stimulation based on shank orientation using a uniaxial gyroscope during gait". In: *Medical and Biological Engineering and Computing*, 1741-0444 (Online).
- Nazarpour, K., Sharafat, R. A. e Firoozabadi, P. M. S. (2007). "Application of Higher Order Statics to Surface Electromyogram Signal Classification". In: *IEEE Trans. on Biomedical Eng.*, (54)10, 1762-1769.

- Oskoei, M. A. e Hu, H. (2006). "GA-based Feature Subset Selection for Myoelectric Classification". In: *Proceedings of the 2006 IEEE International Conference on Robotics and Biomimetics*, 1465-1470.
- Oskoei, M. A. e Hu, H. (2007). "Myoelectric Control Systems - A survey". In: *Biomedical Signal Processing and Control*, (2), 275-294.
- Oskoei, M. A. e Hu, H. (2008). "Support Vector Machine-Based Classification Scheme for Myoelectric Control Applied to Upper Limb". In: *IEEE Transactions on Biomedical Engineering*, (55)8, 1956-1964.
- Osuna, E., Freund, R. e Girosit, F. (1997). Training support vector machines: an application to face detection". In: *Proceedings IEEE Conference Comput. Vis. Pattern Recognit.*, 130-136.
- Parker, P., Englehart, K., Hudgins B. (2006). "Myoelectric signal processing for control of powered limb prostheses". In: *Journal of Electromyography and Kinesiology*, (16) 541-548.
- Park, S.H. e Lee, S.P. (1998). "EMG pattern recognition based on artificial intelligence techniques". In: *IEEE Trans. Rehabil. Eng.*, (6)4, 400-405.
- Peleg, D., Braiman, E., Yom-Tov, E., e Inbar G. F. (2002). "Classification of Finger Activation for Use in a Robotic Prosthesis Arm". In: *IEEE Trans. on Neural System and Rehabilitation Eng.*, (10)4, 290-293.
- Phinyomark, A., Limsakul, Ch. e Phukpattaranont, P. (2009). "A Comparative Study of Wavelet Denoising for Multifunction Myoelectric Control". In: *International Conference on Computer and Automation Engineering*, 21-25.
- Reaz, M. B. I., Hussain, M. S., e Mohd-Yasin, F. (2006). "Techniques of EMG signal analysis: detection, processing, classification and applications". In: *Biological Procedures Online*, (81), 11-35.
- Ren, X., Hu, X., Wang, Z. e Yan, Z. (2006). "MUAP extraction and classification based on wavelet transform and ICA for EMG decomposition". In: *Med. Biol. Eng. Computing*, (44), 371-382.
- Ropella, K. M. (2007). Introduction to Statistics for Biomedical Engineers. In: Morgan & Claypool.
- Seniam. "Surface Electromyography for Noninvasive Assesment of Muscle" [capturado:12/07/2008], <http://www.seniam.org>

- Silva, J.; Chau, T. e Goldenberg, A. (2003). “MMG-Based Multisensor Data Fusion Prosthesis Control”. In *Proceedings of the 25<sup>th</sup> Annual International IEEE EMBS Conference*, 2909-2912.
- Shrirao, N. A.; Reddy, N. P. e Kosuri, D. R. (2009). “Neural network committees for finger joint angle estimation from surface EMG signals”. In: *Biomedical Engineering Online* (8)2.
- Smith, S. W. (1999). *The Scientist and Engineer’s Guide to Digital Signal processing*. 2(ed.) San Diego: California Technical Publishing.
- Smith, R. J., Tenore, F., Huberdeau, D., Etienne-Cummings, R. e Thakor, N. (2008). “Continuous Decoding of Finger Position from Surface EMG Signals for the Control of Powered Prostheses”. In: *Proceedings of the 30<sup>th</sup> Annual International IEEE EMBS Conference*, 197-200.
- Smith, A., Nanda, P. e Brown, E. E. (2009). “Development of a Myoelectric Control Scheme Based on a Time Delayed Neural Network”. In: *Proceedings of the 31<sup>st</sup> Annual International IEEE EMBS Conference*, 3004-3007.
- Tortora, G. J. (2000). *Corpo Humano: Fundamentos de Anatomia e Fisiologia*. In: Artmed Editora. In: *Proceedings of the 30<sup>th</sup> Annual International IEEE EMBS Conference*, 197-200.
- US Department of Health and Human Services (1992). *Selected topics in Surface Electromyography for Use in Occupational Settings: Expert Perspectives*. In: DHHS NIOSH Publications #91-100.
- Varol, H. A. e Golfarb, M. (2007). “Real-time Intent Recognition for a Powered Knee and Ankle Transfemoral Prosthesis”. In: *Proceedings of the IEEE 10<sup>th</sup> International Conference on Rehabilitation Robotics*, 16-23.
- Vaseghi, S. V. (2000). *Adaptive Filters*. In: *Advanced Digital Signal Processing and Noise Reduction*. 2(ed.) John Wiley & Sons Ltd.
- Wang, G., Wang, Z., Chen, W. e Zhuang, J. (2006) “Classification of surface EMG signals using optimal wavelet packet method based on Davies-Bouldin criterion”. In: *Med. Biol. Eng. Computing*, (44), 865-872.
- Wang, G., Yan, Z., Hu, X., Xie, H., e Wang, Z. (2006). “Classification of surface EMG signals using harmonic wavelet packet transform”. In: *Physiological Measurement*, (27), 1255-1267.

- Winter, D. A. (1990). *Biomechanics and Motor Control of Human Movement*. In: John Wiley & Sons.
- Yi-Hung, L., Hang-Pang, H., Chang-Hsin, W. (2007). "Recognition of Electromyographic Signals Using Cascade Kernel Learning Machine". In: *IEEE/ASME Transaction on Mechatronics*, (12)3, 253-264.
- Yoshikawa, M., Mikawa, M., e Tanaka, K. (2007). "A Myoelectric Interface for Robotic Hand Control Using Support Vector Machine". In: *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2723-2728.
- Zecca, M., Micera, S., Carrozza, M. C., Dario, E. P. (2002). "Control of Multifunctional Prosthetic Hands by Processing the Electromyographic Signal". In: *Critical Reviews<sup>TM</sup> in Biomedical Engineering*, (4-6)30, 459-485.
- Zardoshti-Kermani, M., Wheeler, B. C., Badiem, K. e Hashemi, R. M. (1995). "EMG Feature Evaluation for Movement Control of Upper Extremity Prosthesis". In: *IEEE Trans. on Rehabilitation Eng.*, (3), 324- 333.
- Zhao, J., Xie, Z., Jiang, L. e Cai, H. (2005). "Levenberg-Marquardt Based Neural Network Control for a Five-fingered Prosthetic Hand". In: *Proceedings of IEEE International Conference on Robotics and Automation*, 4482-4487.
- Zhao, J., Xie, Z., Jiang, L., Cai, H., Lio, H. e Hirzinger, G. (2006). "EMG control for a five-fingered interactuated prosthetic hand based on wavelet transform and sample entropy". In: *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems*, 3215-3220.
- Zhang, Y. T., Parker, P. A., Scott, R. N. (1997). "Signal-to-Noise Ratios of the Myoelectric Channel with Additive Noise". In: *Proceedings of the 19<sup>th</sup> International Conference IEEE/EMBS*, 1582-1584.

## **APÊNDICES**

**A- ZONAS DE ESTUDO UTILIZADAS DURANTE A IMPLEMENTAÇÃO DO SEGUNDO PROTOCOLO EXPERIMENTAL NOS MÚSCULOS AGONISTAS E ANTAGONISTAS**




Figura A.1- Sujeito #1.




Figura A.2- Sujeito #2.




Figura A.3- Sujeito #3.




Figura A.4- Sujeito #4.



Figura A.5- Sujeito #5.

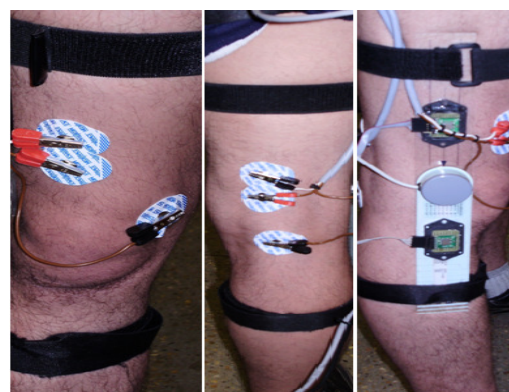


Figura A.6- Sujeito #6.






Figura A.7- Sujeito #7.




Figura A.8- Sujeito #8.




Figura A.9 - Sujeito #9.

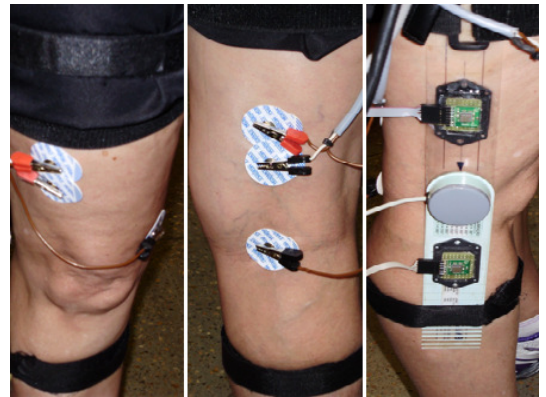


Figura A.10- Sujeito #10.




Figura A.11- Sujeito #11.




Figura A.12-Sujeito #12.

## B- SINAIS OBTIDOS DURANTE O PROTOCOLO EXPERIMENTAL NOS DOZE VOLUNTARIOS




Figura B.1- Sujeito #1.




Figura B.2- Sujeito #2.




Figura B.3- Sujeito #3.




Figura B.4- Sujeito #4.




Figura B.5- Sujeito #5.




Figura B.6- Sujeito #6.




Figura B.7- Sujeito #7.




Figura B.8- Sujeito #8.




Figura B.9- Sujeito #9.




Figura B.10- Sujeito #10.




Figura B.11- Sujeito #11.




Figura B.12- Sujeito #12.

**C- TERMO DE LIVRE CONSETIMENTO E ESCLARECIDO.  
CERTIFICO DE ACEITAÇÃO DO PROTOCOLO  
EXPERIMENTAL SUBMETIDO AO COMITÊ DE ÉTICA EM  
PESQUISA DA UNB**



Universidade de Brasília – UnB  
Faculdade de Tecnologia  
Departamento de Elétrica

Pesquisa: “Avaliação de algoritmos para estimação contínua de deslocamento do joelho em prótese trans femoral, a partir da coleta de variáveis eletromiográficas e proprioceptivas em indivíduos saudáveis”.

Pesquisador Responsável: Alberto López Delis

Telefone para contato: Telefone: 61 -8174-7493

Endereço para contato: SQN 405 Bloco D Apto. 105 Asa Norte – DF CEP: 70834-040

Orientador: Prof. Dr Adson Ferreira da Rocha

Telefone: 61- 3307-2328 (ramal 231)

Universidade de Brasília – UNB | Faculdade de Ciências da Saúde

Comitê de Ética em Pesquisa com seres Humano – CEP/FS

Telefone: 3307-3799 | email:cepfs@unb.br | site:www.unb.br/fs/cep

**Termo de Consentimento Livre e Esclarecido**

Eu, Alberto López Delis, pesquisador responsável do projeto de pesquisa venho convidar o participante \_\_\_\_\_ para contribuir na pesquisa visando o estudo nos indivíduos do sexo masculino entre as idades de (23-57) anos, saudáveis, com o objetivo de implementar coleta de sinais eletromiográficas de superfície em músculos agonistas e antagonistas relacionados aos

movimentos de flexão e extensão do joelho e variáveis proprioceptivas relacionadas à intenção de movimento. Esta informação será proveniente de um sistema de instrumentação biomédico (equipamento eletrônico) que permitirá avaliar algoritmos (programa de computador – localizado dentro do equipamento) desenvolvidos para a extração e classificação de padrões mioelétricos, para estimação contínua do joelho, com vistas ao controle de prótese transfemoral. O trabalho em questão poderá contribuir a demonstrar as potencialidades dos algoritmos em sua avaliação, para sua inclusão no desenvolvimento futuro da prótese de perna.

Qualquer dúvida em relação à pesquisa do protocolo experimental será o seu conteúdo esclarecido, estando o convidado livre para abandonar a pesquisa sem qualquer constrangimento e despesas financeiras, no momento que lhe for oportuno ou necessário.

Caso ocorra algum dano ou se sinta lesado decorrentes de sua participação na pesquisa o senhor poderá pleitear indenização. Não haverá nenhum tipo de pagamento ou gratificação financeira pela sua participação na pesquisa.

Caso haja alguma despesa realizada decorrente da participação na pesquisa tais como: ônibus, gasolina, alimentação pré-aplicação ou qualquer outro relativo aos preparativos o senhor terão direito a ressarcimento.

O participante será informado que sua identidade será preservada e que os dados coletados poderão ser publicados posteriormente em revistas e jornais e apresentados em congressos somente após o consentimento livre e assinatura do Termo de Consentimento Livre e Esclarecido.

Brasília/DF, \_\_\_\_\_ de \_\_\_\_\_ de 2009.

---

Assinatura do participante

RG \_\_\_\_\_

---

Assinatura do pesquisador responsável – Alberto López Delis



## PROCESSO DE ANÁLISE DE PROJETO DE PESQUISA

Registro do Projeto no CEP: **079/09**

Título do Projeto: “Avaliação de algoritmos para estimação contínua de deslocamento do joelho em prótese transfemoral, a partir de coleta de variáveis eletromiográficas e propioceptivas em indivíduos saudáveis”.

Pesquisador Responsável: Alberto Lopez Delis

Data de Entrada: 21/08/2009

Com base na Resolução 196/96, do CNS/MS, que regulamenta a ética em pesquisa com seres humanos, o Comitê de Ética em Pesquisa com Seres Humanos da Faculdade de Ciências da Saúde da Universidade de Brasília, após análise dos aspectos éticos e do contexto técnico-científico, resolveu **APROVAR** o projeto **079/09** com o título: “Avaliação de algoritmos para estimação contínua de deslocamento do joelho em prótese transfemoral, a partir de coleta de variáveis eletromiográficas e propioceptivas em indivíduos saudáveis”, analisado na 8ª Reunião Ordinária, realizada no dia 8 de setembro de 2009.

O pesquisador responsável fica, desde já, notificado da obrigatoriedade da apresentação de um relatório semestral e relatório final sucinto e objetivo sobre o desenvolvimento do Projeto, no prazo de 1 (um) ano a contar da presente data (item VII.13 da Resolução 196/96).

Brasília, 19 de outubro de 2009.



Prof. Volnei Garrafa  
Coordenador do CEP-FS/UnB

## D- DESCRIÇÃO DO CD

1. Tese em formato PDF.
2. Esquemas elétricos do sistema de bioinstrumentação em formato PDF
3. Banco de dados dos sinais mioelétricos e sensores proprioceptivos coletadas nos doze indivíduos durante o segundo protocolo experimental.

Para visualizar o conjunto dos sinais mioelétricos e sensores proprioceptivos:

- a) Deve ser executado o programa *Matlab* e configurada a pasta no qual se encontram os arquivos da base de dados.
- b) A continuação desde a janela de comandos deve ser executado o programa **read\_data\_1**, colocando como argumento o nome do arquivo que se deseja visualizar. A função permite visualizar o conjunto dos sinais mioelétricos coletadas em músculos antagonistas, a informação do ângulo de deslocamento do joelho fornecida pelo eletrogoniômetro e a informação da velocidade angular coletada no músculo e a perna, a partir dos sensores giroscópios. A seguinte figura apresenta uma visualização do conjunto dos sinais desde o programa *Matlab*.

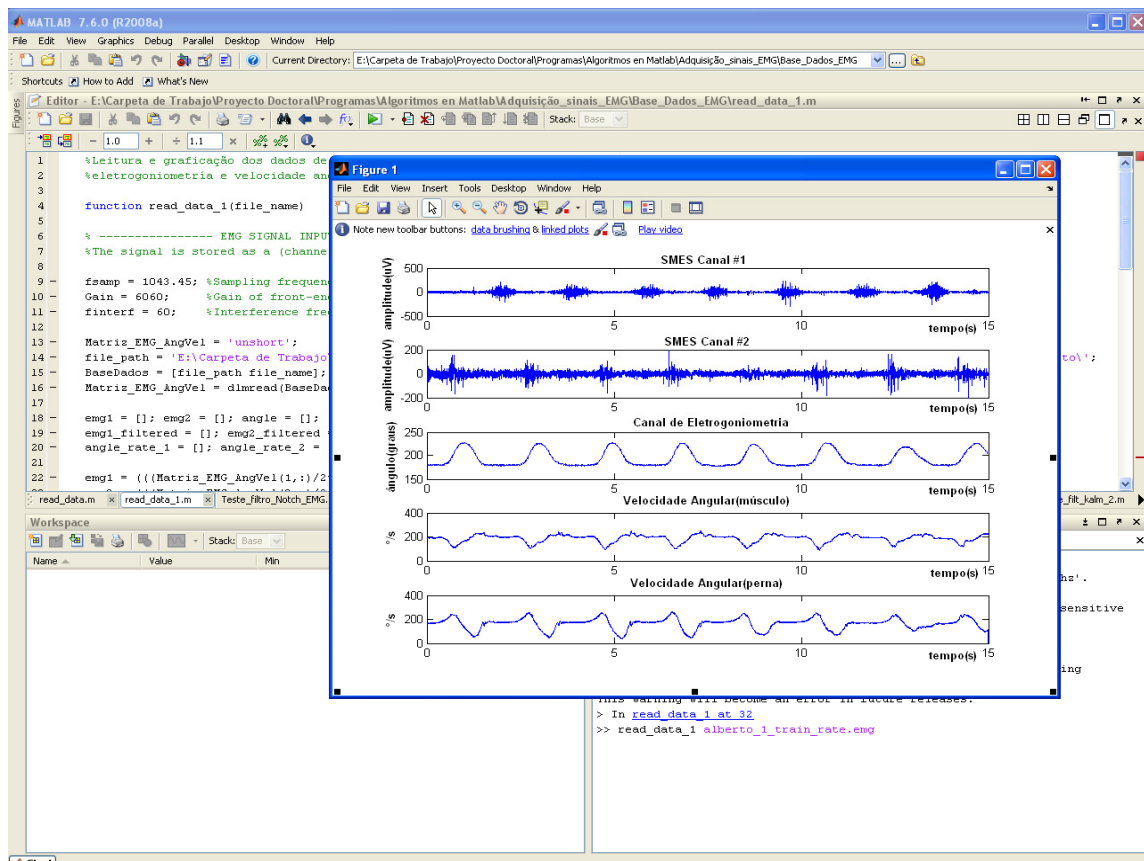


Figura D- Visualização do conjunto dos sinais mioelétricos e proprioceptivos desde o Matlab.



# E- DIAGRAMAS ESQUEMÁTICOS DO SISTEMA DE BIOINSTRUMENTAÇÃO

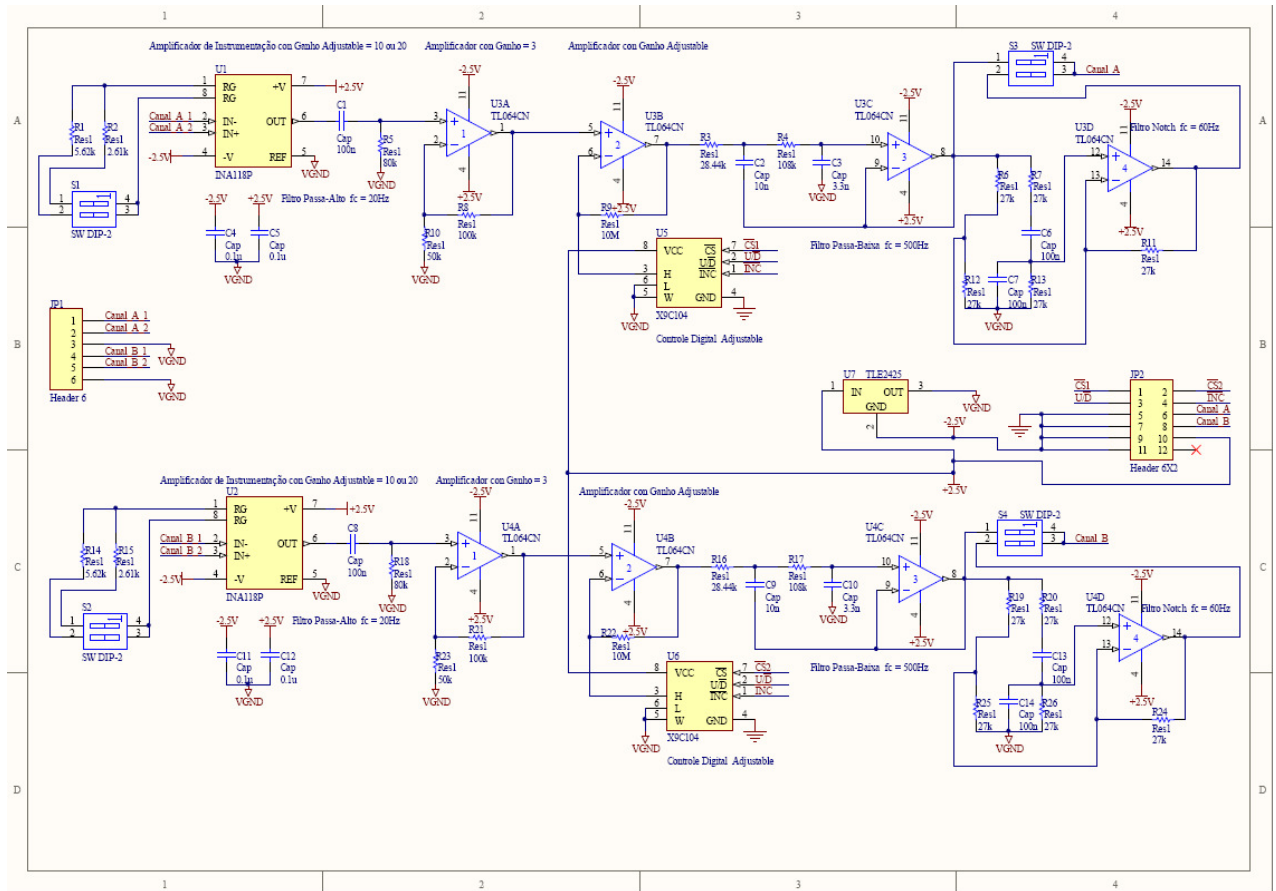


Figura E1- Módulo *Front-End* de baixa frequência.

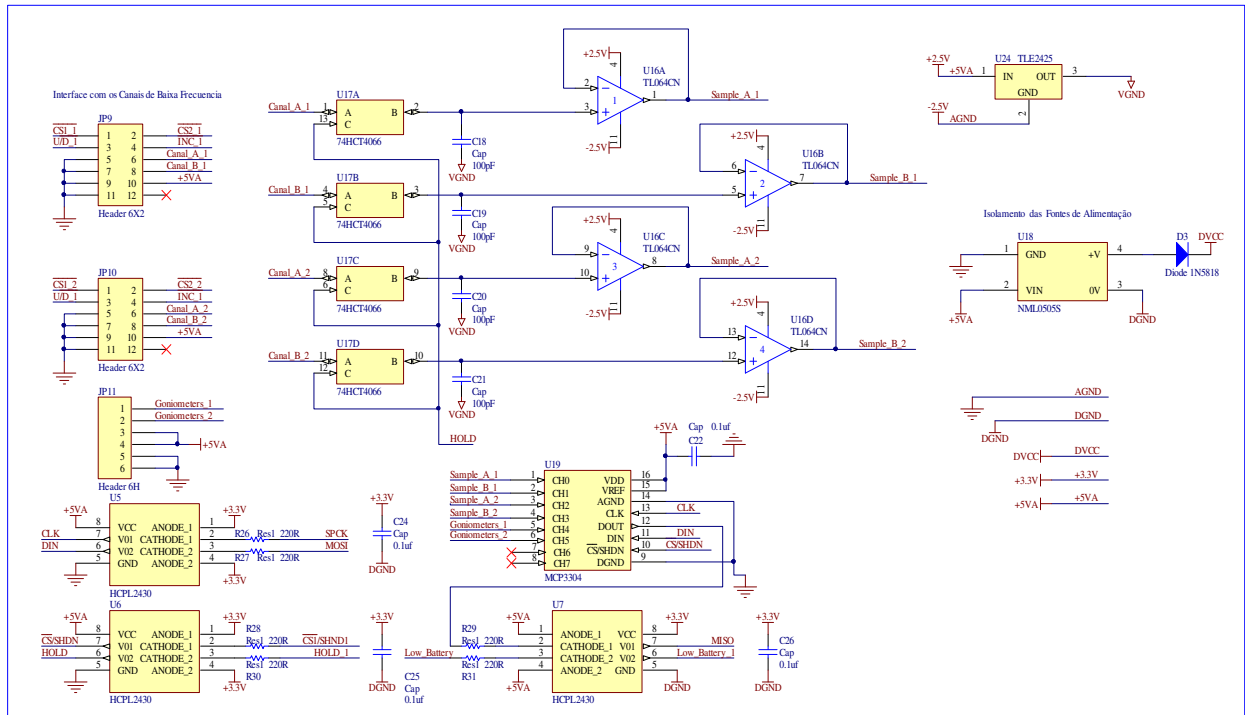


Figura E2- Módulo de aquisição.

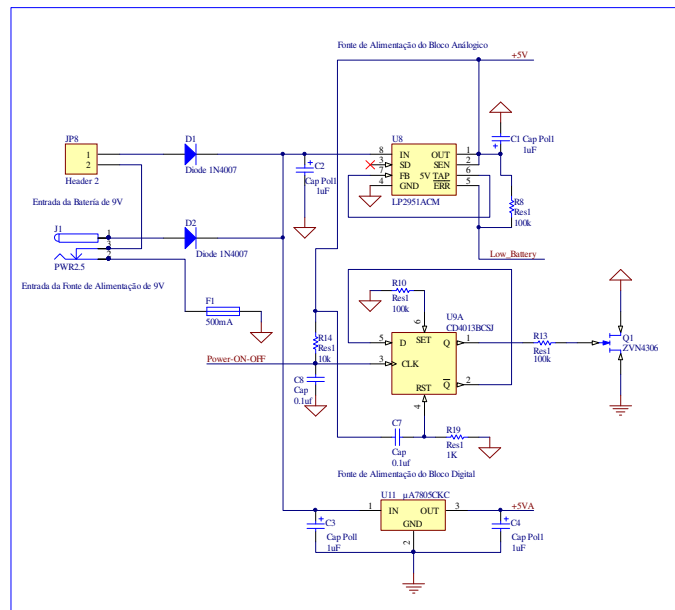


Figura E3- Módulo da fonte de tensão.

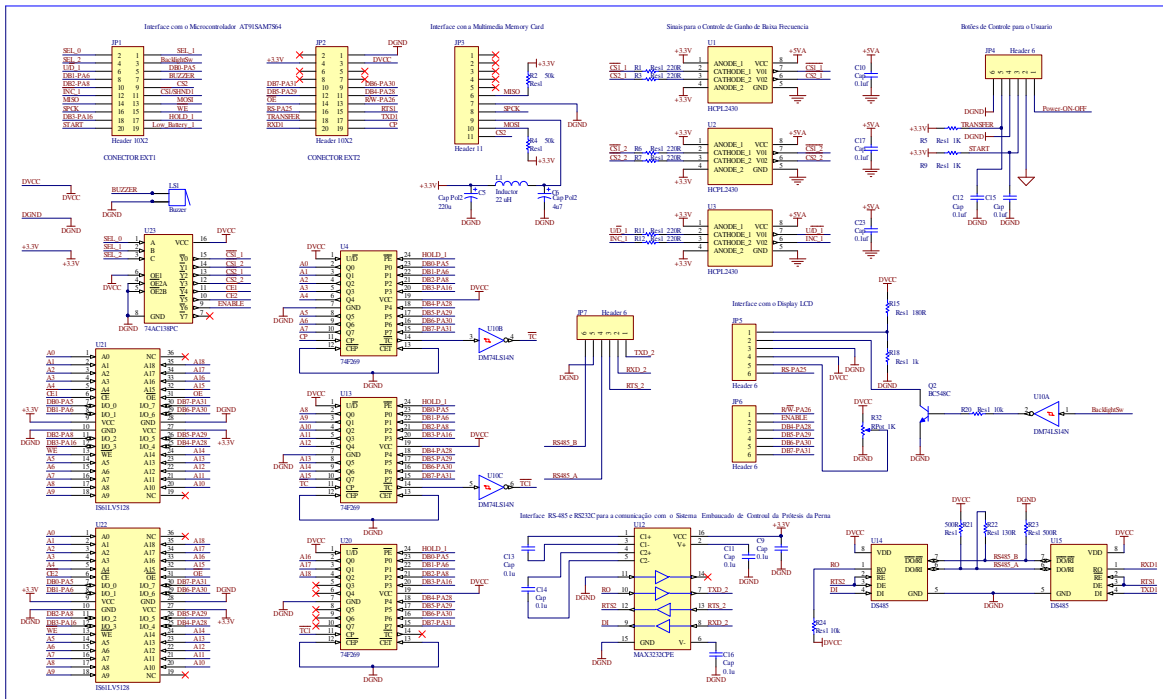


Figura E4- Módulo do bloco digital.