USP

Campus de São Carlos

DECOMPOSIÇÃO DE SINAIS MIOELÉTRICOS SUPERFICIAIS: AVALIAÇÃO NÃO-INVASIVA DE DESORDENS NEUROMUSCULARES

Autor: Samuel Waldemar Andrade Flôr

Orientador: Prof. Dr. Alberto Cliquet Junior

UNIVERSIDADE DE SÃO PAULO

ESCOLA DE ENGENHARIA DE SÃO CARLOS

Serviço de Pós-Gradução EESC/USP

EXEMPLAR REVISADO

Data de entrada no Serviço: 01/09/03

Ass.:

DECOMPOSIÇÃO DE SINAIS MIOELÉTRICOS SUPERFICIAIS: AVALIAÇÃO NÃO-INVASIVA DE DESORDENS NEUROMUSCULARES

Samuel Waldemar Andrade Flôr

Tese apresentada ao Departamento de Engenharia Elétrica da Escola de Engenharia de São Carlos, da Universidade de São Paulo, para obtenção do título de Doutor em Engenharia Elétrica – Área: Automação – opção: Engenharia de Reabilitação.

Orientador: Prof. Dr. Alberto Cliquet Junior

DEDALUS - Acervo - EESC

31100044177

EESC-USP Biblioteca Campus de S. Carlos

São Carlos
Julho, 2003

Class. TESE-EESC
Cutt. 2238
Tombo T292/03
Sysno 1333234

F632d

Flor, Samuel Waldemar Andrade
Decomposição de sinais mioelétricos superficiais : avaliação não - invasiva de desordens neuromusculares / Samuel Waldemar Andrade Flor. -- São Carlos, 2003.

Tese (Doutorado) -- Escola de Engenharia de São Carlos-Universidade de São Paulo, 2003.
Área : Engenharia Elétrica.
Orientador: Prof. Dr. Alberto Cliquet Junior.

1. Decomposição de EMG de superfície. 2. Disfunções neuromusculares. 3. EMG superfície. 4. Filtro passa-baixas diferencial. 5. Estatísticas IPI. 6. Mapa SOM. 7. Potencial de ação. 8. Rede neural artificial. 9. Unidade motora. I. Título.

FOLHA DE JULGAMENTO

Candidato: Engenheiro **SAMUEL WALDEMAR ANDRADE FLOR**

Tese defendida e julgada em 18-08-2003 perante a Comissão Julgadora:

APROVADO

Prof. Tit. **ALBERTO CLIQUET JUNIOR (Orientador)**
(Escola de Engenharia de São Carlos/USP)

APROVADO

Prof. Dr. **MARCELO BASÍLIO JOAQUIM**
(Escola de Engenharia de São Carlos/USP)

APROVADO

Prof. Dr. **NIVALDO ANTONIO PARIZOTTO**
(Universidade Federal de São Carlos/UFSCar)

Aprovado

Prof. Liv. Doc. **LAECIO CARVALHO DE BARROS**
(Universidade Estadual de Campinas/UNICAMP)

APROVADO

Prof. Dr. **JOSÉ BAPTISTA PORTUGAL PAULIN**
(Faculdade de Medicina de Ribeirão Preto/USP)

Prof. Assoc. **MURILO ARAUJO ROMERO**
Coordenador do Programa de Pós-Graduação
Em Engenharia Elétrica

Profa. Assoc. **MARIA DO CARMO CALIJURI**
Presidente da Comissão de Pós-Graduação

"Mas a vida é curta e a informação infinita...

Abreviações são um mal necessário e a tarefa do abreviador é fazer o melhor trabalho que, embora intrinsecamente ruim, seja ainda melhor que nada."

Aldous Huxley

À minha esposa

AGRADECIMENTOS

- Ao Prof. Alberto Cliquet Junior pela confiança em mim depositada, pela disposição contínua em resolver os problemas, pelo estímulo e orientação.
- Ao Prof. Marcio L. Andrade Neto (DCA/Unicamp), pela cooperação e apoio inicial para o desenvolvimento desta pesquisa.
- À Profª. Rosângela e a Kelly (Lab. Eletromiografia/UFSCar), pelo auxilio no trabalho com os pacientes portadores de síndrome de Duchenne.
- Ao Ênio (Fisioterapia/HC/Unicamp), pela amizade e apoio no trabalho com os pacientes portadores de paralisia cerebral.
- Aos colegas do LABCIBER/USP pelas discussões técnicas, pela colaboração e pela convivência agradável.
- Aos funcionários das bibliotecas (EESC, BAE/Unicamp), cujo apoio foi essencial para a realização da pesquisa bibliográfica.
- Aos colegas do LCA/Unicamp pela convivência e amizade.
- À minha esposa pela paciência e compreensão, cuja perseverança me serve de exemplo.
- Aos meus filhos (Mozart e Murilo) porque entenderam, ou pelo menos tentaram entender a minha ausência.
- Aos pacientes que colaboraram com esta pesquisa, que mesmo sofrendo as privações de suas patologias ainda conseguiam sorrir..., e cuja esperança é nossa maior motivação.
- À todos que de forma direta ou indireta contribuíram com esta pesquisa.

SUMÁRIO

LISTA DE FIGURAS

LISTA DE TABELAS

LISTA DE ABREVIATURAS

RESUMO

ABSTRACT

CAPÍTULO 1 – INTRODUÇÃO 1

1.1. Considerações iniciais 1
1.2. Justificativa do trabalho 9
1.3. Disposição do trabalho 12

CAPÍTULO 2 – BASES ELETROFISIOLÓGICAS DA EMG 14

2.1. Breve Histórico 14
2.2. Fundamentos da Eletromiografia 15
2.3. Bases Eletrofisiológicas da EMG 18
2.4. Processo contrátil num músculo esquelético 28
2.5. Fatores que determinam a força de contração de um músculo esquelético durante seu trabalho 32

CAPÍTULO 3 – COMPENSAÇÃO DO EFEITO DOS TECIDOS SUBCUTÂNEOS NA EMG DE SUPERFÍCIE 34

3.1. Introdução 34
3.2. Eletromiografia de superfície de alta resolução espacial 40
3.3. Aplicação em diagnóstico de desordens neuromusculares 44

CAPÍTULO 4 – DECOMPOSICÃO DE SINAIS MIOELÉTRICOS 46

4.1. Introdução 46

4.2. Composição do sinal eletromiográfico 46

4.2.1. Potencial de ação da fibra muscular (MFAP) 47

4.2.2. Potencial de ação da unidade motora (MUAP) 47

4.2.3. Trem de potenciais de ação da unidade motora (MUAPT) 49

4.2.4. Sinal EMG composto 50

4.3. Como um sinal EMG pode ser decomposto? 55

4.3.1. Suposições básicas 55

4.3.2. Aquisição do sinal 56

4.3.2.1 Protocolo de detecção do sinal 56

4.3.2.2 Atributos interessantes do sinal EMG 57

4.3.2.3 Seleção da taxa de amostragem 57

4.3.3. Segmentação do sinal composto (detectando MUAPs) 58

4.3.4. Extração de características para reconhecimento de padrão 61

4.3.4.1 Considerações sobre espaço característico 61

4.3.4.2 Espaços característicos 62

4.3.5. Agrupamento dos MUAPs detectados (clustering) 62

4.3.5.1 Medida de distância 62

4.3.5.2 Técnicas de agrupamento clássicas 64

4.3.6. Algoritmos de agrupamento usados para decomposição de sinais EMG 66

4.3.7. Classificação supervisionada dos MUAPs detectados 69

4.3.7.1 Fatores que afetam a classificação supervisionada 70

4.3.8. Resolução de MUAPs superpostos 72

4.3.9. Descobrindo relações temporais entre MUAPTs 75

4.3.9.1 Definindo e medindo a interdependência entre MUAPTs 76

4.3.9.2 Importância da descoberta das relações temporais entre MUAPTS 77

4.3.10. Avaliação da decomposição do sinal EMG 77

4.3.10.1 Avaliação quantitativa 77
4.3.10.2 Avaliação qualitativa 80

4.4. Usando os resultados da decomposição 82
4.4.1. Doenças e alterações morfológicas nos MUAPs 82
4.4.2. Disparos da unidade motora e padrões de recrutamento 83

4.5. O status atual da decomposição de sinais EMG 86

CAPÍTULO 5 – AQUISIÇÃO DE DADOS E GERAÇÃO DOS CONJUNTOS DE TREINAMENTO 89

5.1. Protocolo para aquisição dos sinais EMG 89
5.2. Geração do conjunto de treinamento 94

CAPÍTULO 6 – MAPAS AUTO-ORGANIZÁVEIS DE KOHONEN PARA CLASSIFICAÇÃO DE MUAPS 99

6.1. Introdução 100
6.2. Aprendizado Competitivo 101
6.3. Estrutura básica do SOM 104
6.4. Treinamento do SOM 107
6.4.1. Algoritmo convencional 107
6.4.2. Comentários sobre o processo de treinamento do SOM 109
6.4.3. Escolha dos parâmetros de treinamento 113
6.4.3.1 Dimensionalidade e tamanho do mapa 113
6.4.3.2 Conectividade entre neurônios e topologia da rede 115
6.4.3.3 Inicialização dos pesos 116
6.4.3.4 Funções para decaimento da vizinhança ao redor do *BMU* e da taxa de aprendizagem 117
6.4.3.5 Número de épocas 118
6.4.4. Algoritmo em lote ou paralelo 119
6.4.5. Um algoritmo mais eficiente para redução do tempo de treinamento 120
6.4.6. Exemplo de uso do SOM 121

6.5. Segmentação e rotulação dos mapas de Kohonen 130
6.5.1. Visualização dos mapas de kohonen a *U-matrix* 131
6.5.2. Segmentação da *U-matrix* 136
6.5.2.1 A transformada *watershed* 140
6.5.3. Rotulagem das regiões conectadas 144

6.6. Sumário 151

CAPÍTULO 7 – RESULTADOS EXPERIMENTAIS E DISCUSSÃO 153

7.1. Resultados da decomposição 153
7.2. Avaliação da decomposição 157
7.2.1. Detecção de erros de classificação 160
7.2.2. Testes para avaliação da métrica usada 165
7.2.2.1 Teste do coeficiente de variação 166
7.2.2.2 Teste de dados perdidos 167
7.2.2.3 Teste do período de aquisição 168
7.2.2.4 Teste da razão entre IPIs médios 170
7.2.3. Resultados da detecção de erros de classificação 171

7.3. Conclusões 171

CAPÍTULO 8 – ESTUDO CLÍNICO A PARTIR DE CARACTERÍSTICAS MORFOLÓGICAS DOS MUAPs 173

8.1. Introdução 173
8.2. Material 175
8.3. Coleta de dados e análise no domínio do tempo 176
8.4. Modelagem autoregressiva e cepstral 178
8.4.1. Teste de estacionaridade 178
8.4.2. Modelagem AR e seleção da ordem do modelo 178
8.4.3. Estimação espectral 180
8.4.4. Análise cepstral 181
8.5. Classificação de patologias com redes neurais 181
8.6. Resultados e discussões 182

8.6.1. Análise no domínio do tempo 182
8.6.2. Análise autoregressiva 184
8.6.3. Estimativas espectrais 185
8.6.4. Análise cepstral 186
8.6.5. Classificação de patologias com redes neurais 187

8.7. Observações e Conclusões 189

CAPÍTULO 9 – CONSIDERAÇÕES FINAIS 190

CAPÍTULO 10 – REFERÊNCIAS BIBLIOGRÁFICAS 193

SUGESTÕES PARA TRABALHOS FUTUROS 203

LISTA DE FIGURAS

Figura 1.1 – Decomposição do sinal mioelétrico é o processo de descoberta dos MUAPTs constituintes significantes que contribuem para o sinal mioelétrico detectado, (adaptado de De Luca et al., 1982). 4

Figura 1.2 – Diagrama de blocos do sistema de decomposição. 11

Figura 2.1 – A Unidade Motora e o diagnóstico eletroneuromiografico. O conjunto formado por um motoneurônio alfa e as fibras musculares estriadas dele dependentes constituem uma unidade motora. 16

Figura 2.2 – Um MUAP é composto do somatório dos potenciais de ação das fibras musculares (MFAP) componentes da UM. A localização da fibra muscular relativa ao eletrodo, a área superficial, a configuração do eletrodo e o diâmetro da fibra afeta grandemente esta contribuição. MUAPs para uma UM em particular variam devido a variações aleatórias no inicio dos MFAPs e a diferentes velocidades de condução do potencial de ação da fibra muscular (de Basmajian & De Luca, 1985). 17

Figura 2.3 – Diferença de potencial gerada na membrana celular devido às diferenças nas concentrações iônicas entre os meios intra e extracelular, as quais são mantidas constantes no repouso. 20

Figura 2.4 – Membrana celular, (Guyton & Hall: Medical Physiology). 20

Figura 2.5 – Ilustração do processo de abertura de um canal iônico provocado pela alteração conformacional de uma proteína por sua ligação com uma substância ligante. 21

Figura 2.6 – Resposta de uma célula nervosa a estímulos de corrente. 23

Figura 2.7 – Geração do potencial de ação. 24

Figura 2.8 – A propagação do impulso nervoso ao longo do axônio, mostrando locais ricos em canais de sódio e potássio sensíveis à voltagem, na membrana plasmática. Nos locais assinalados pelas setas está ocorrendo despolarização maior que 100 mV, seguida de repolarização, ou seja, um potencial de ação representado na parte de cima da figura (Fig. 34.112 – Voet). 26

Figura 2.9 – Resposta de uma célula nervosa a diferentes estímulos de corrente. 27

Figura 2.10 – Constituição de um músculo esquelético típico. 28

Figura 2.11 – O potencial de ação (PA) ganha as fibras musculares e é interiorizado para as miofibrilas através dos túbulos T. No Retículo Sarcoplasmático os PAs promovem aumento da permeabilidade da membrana à saída de Ca++ armazenado para o sarcoplasma, (adaptado de Guyton & Hall: Medical Physiology). 29

Figura 2.12 – A alta concentração de Ca++ no sarcoplasma ativa a Troponina-C (TN-C), alterando a configuração estrutural, (Guyton & Hall: Medical Physiology) 30

Figura 2.13 – A alteração da configuração estrutural desloca tropomiosina para sulco dos filamentos actina. Ocorre a exposição dos sítios de fixação para meromiosina pesada e uma molécula de ATP, formando as PONTES CRUZADAS. O ATP promove uma flexão do filamento de miosina (dobradiça) e o deslizamento entre os filamentos,(Guyton & Hall: Medical Physiology) 31

Figura 3.1 – (a) Zona de despolarização da fibra muscular, descrição da corrente de membrana, e do potencial de superfície monopolar V_S gerado sobre a pele por duas zonas despolarizadas em duas profundidades h_1 e h_2; (b) Voltagem transmembrana da fibra muscular, corrente e modelo tripolo da corrente transmembrana; (c) Representação esquemática de uma unidade motora (três fibras somente) e do sinal detectado pelo amplificador diferencial (eletrodos de superfície) ou por um de agulha coaxial. Dimensões físicas não estão em proporções corretas, (Farina & Rainoldi, 1999). 36

Figura 3.2 – Distribuição de potencial e secção ao longo do eixo z gerada por dois tripolos a uma profundidade de 2 mm e a uma distancia de 5 mm ao longo do eixo x e 50 mm ao longo do eixo z, obtido com diferentes sistemas de detecção: monopolar, duplo diferencial, filtro binomial inverso de segunda ordem e filtro inverso aproximado. Os gráficos da coluna à direita mostram o sinal de saída detectado pelo sistema de detecção posicionado em x=0, (adaptado de Farina et al., 2002). 39

Figura 3.3 – Diagrama da distribuição de potencial $\Phi(x)$ gerado na superfície da pele por duas unidades motoras distintas (MU1 e MU2) num dado momento. É assumido que MU1 está mais próxima da superfície da pele e MU2 mais distante.Devido a maior proximidade da superfície MU1 produz uma distribuição de potencial espacialmente íngreme. Em contraste, MU2 produz uma distribuição espacialmente plana. Usando

condutores bipolares com uma grande distância intereletródica ambas UMs contribuem significativamente para o sinal diferença resultante (lado esquerdo). No caso de pequenas distâncias intereletródicas, a MU1 contribui com a maior parte do sinal medido (lado direito). Este princípio é conhecido como filtragem espacial high-pass da distribuição de potencial. (Adaptado de Disselhorst-klug et al., 2000). 42

Figura 3.4 – Representação de quatro diferentes configurações de eletrodos usados na aquisição do sinal mioelétrico do músculo abdutor pollicis brevis sob contração voluntária máxima. Uma excitação de uma UM foi enfatizada. (Rau & Disslhorst-Klug, 1997). 43

Figura 3.5 – Sinal EMG-ARE de crianças com diferentes tipos de desordens neuromusculares. (Rau & Disselhorst-Klug, 1997). 45

Figura 4.1 – Um MUAP é composto do somatório dos potenciais de ação das fibras musculares (MFAP) componentes da UM. A localização da fibra muscular relativa ao eletrodo, a área superficial, a configuração do eletrodo e o diâmetro da fibra afeta grandemente esta contribuição. MUAPs para uma UM em particular variam devido a variações aleatórias no inicio dos MFAPs e a diferentes velocidades de condução do potencial de ação da fibra muscular (Basmajian & De Luca, 1985). 48

Figura 4.2 – Modelo fisiológico e matemático para a composição do sinal EMG detectado, (Basmajian e De Luca, 1985). 50

Figura 4.3 – Os efeitos da filtragem passa-banda na forma e distinção dos MUAPs. Nota-se que com a diferenciação passa-baixas os MUAPs têm sua duração reduzida e os MUAPs criados por cada uma das três UMs, aqui contribuintes, podem ser mais facilmente discriminados (McGill & Dorfman,1989). 59

Figura 4.4 – Exemplo de detecção de um sinal EMG que foi diferenciado em passa-baixas. Traço superior mostra um segmento de EMG bruto. O traço do meio mostra o mesmo segmento após passar por um filtro diferenciador passa-baixas de segunda ordem indicando os MUAPs significantes detectados. O traço de baixo mostra as médias das formas de onda das UMs que contribuíram significantemente para o segmento de EMG mostrado (McGill & Dorfman, 1989). 60

Figura 4.5 – Parâmetros do MUAP no domínio do tempo (estatísticas morfológicas). 62

Figura 4.6 – Exemplo da saída de um algoritmo de agrupamento que usa a informação da forma de onda do MUAP e do padrão de disparo da UM. Para um intervalo analisado de 5 s; (a) Resultados padrões determinados manualmente; (a) Formas protótipos; (b) MUAPs associados; (c) Padrão de disparo da UM. Falhas no padrão de disparo são causadas por superposições de MUAPs não resolvidas. (b) Resultados do algoritmo de agrupamento. (a), (b) e (c) idem (a). Os grupos 2 e 5 estão duplicados e juntos representam a atividade da UM #2. Eles foram criados devido a não estacionaridade do sinal e podem ser fundidos por um algoritmo de classificação supervisionada [Nandedkar et al., 1995]. 69

Figura 4.7 – Definições de superposição de MUAPs. São ilustradas quatro formas de onda de MUAPs e suas superposições para diferentes deslocamentos no tempo. (a) Formas de onda dos MUAPs; (b) superposição parcial; (c) superposição completa; (d) superposição destrutiva. 73

Figura 4.8 – Exemplo de resolução de superposição de MUAPs: (a) Forma de onda modelo candidata; (b) segmentos do sinal contendo um MUAP superposto e outro classificado; (c) MUAPs superpostos resolvidos com outros classificados; (d) resíduos. 75

Figura 4.9 – MUAPs similares em dois MUAPTs diferentes. Diagrama temporal com os MUAPs alinhados. O tempo de disparo em segundos é mostrado no lado esquerdo de cada diagrama e o IPI em ms no lado direito. Os MUAPs em cada trem são similares na forma e a informação do padrão de disparo é útil na discriminação entre MUAPs criados por cada UM. 80

Figura 4.10 – Resultados da decomposição de um sinal EMG típico com subseqüente análise. A primeira coluna mostra para cada MUAPT o MUAP protótipo (modelo) com o número de MUAPs isolados contidos no trem e usados para sua estimação. A segunda coluna apresenta os histogramas de IPIs com a média, desvio padrão e coeficiente de variação do máximo principal. A terceira coluna mostra o MUAPT com seus tempos de disparo e respectiva taxa de disparo instantânea, ao lado é mostrada a taxa média de disparo de cada UM (adaptado de Nandedkar et al., 1995). 81

Figura 5.1 – Arranjo usado para coleta dos sinais durante as contrações isométricas. Onde T é um dinamômetro de mola, C é uma cinta ajustável presa a uma correia no punho do sujeito. 90

Figura 5.2 – Eletrodo com suporte auto-adesivo (extraído de http://www.delsys.com). 90

Figura 5.3 – A localização preferida é entre o ponto motor e a inserção tendinosa, com as superfícies de detecção arranjadas tal que interceptem o maior número possível de fibras. (extraído de http://www.delsys.com). 92

Figura 5.4 – Um sinal EMG puro e suas saídas filtradas. Topo: segmento de um EMG gravado no bíceps braquial sob contração fraca (~10% CVM) por eletrodos de superfície bipolares amostrado à 10 kHz. Meio: o mesmo segmento filtrado usando um simples filtro DPB (*N=3*). Em baixo: o mesmo segmento filtrado usando um filtro DPBP senoidal. 96

Figura 5.5 – Espectro de potência do sinal puro e do sinal filtrado usando o filtro DPBP senoidal. 96

Figura 5.6 – Exemplo da saída do detector de picos (limiar de detecção a 20%). As formas de ondas dos MUAPs candidatos são extraídas de um segmento de EMG (1s de intervalo, adquirido a menos de 10% da CVM), tendo o pico principal alinhado no meio da janela (largura da janela = 12.8 ms). 97

Figura 5.7 – Estrutura final do conjunto de treinamento. Cada linha da matriz representa um MUAP candidato de comprimento *N*, com o pico principal alinhado no meio do segmento. A ocorrência temporal do pico principal de cada MUAP é gravada num vetor unidimensional indexado ao índice do MUAP candidato. A informação de norma é gravada num vetor unidimensional separado. 98

Figura 6.1 – Esquema simplificado de uma rede neural competitiva, (Kohonen, 1997). 102

Figura 6.2 – Esquema de atualização dos pesos em uma rede neural competitiva. 103

Figura 6.3 – SOM com tamanho 7*x*10 e dimensionalidade de entrada, $p = 3$, (Kohonen, 1997). 106

Figura 6.4 – Duas configurações de grade e níveis de vizinhança do neurônio vencedor aos neurônios circunvizinhos, (Kohonen, 1997). 107

Figura 6.5 – Som com tamanho 4*x*4 e dimensionalidade de entrada, p =3. 107

Figura 6.6 – Conjunto de dados gerado artificialmente. 122

Figura 6.7.a – Grade do SOM 40x1 após inicialização linear. 122

Figura 6.7.b – Grade do SOM 40x1 após 1000 iterações batch. 123

Figura 6.7.c – Histograma de vencedores para o SOM 40x1. 123
Figura 6.8 – Grade após inicialização linear de uma rede SOM de tamanho 10x10. 124

Figura 6.9 – Grade do SOM 10x10 após 1000 iterações do algoritmo em lote e inicialização linear. 124

Figura 6.10 – Histograma de vencedores para o SOM 10x10. 125

Figura 6.11 – Quantização obtida após 1000 iterações. 126

Figura 6.12 – Superfície de influências dos neurônios em 2D. 126

Figura 6.13 – Quantização obtida considerando apenas neurônios ativos com $H(i,j) > 1$. 128

Figura 6.14 – Superfície de influências para a configuração de neurônios, apresentada na Figura 6.13, $H(i,j) > 1$. 128

Figura 6.15 – Quantização obtida considerando apenas neurônios ativos com $H(i,j) > 7$. 129

Figura 6.16 – Superfície de influências para a configuração de neurônios apresentada na Figura 6.15, $H(i,j) > 7$. 129

Figura 6.17 – Superfície de influências para a configuração de neurônios apresentada na Figura 6.15, $H(i,j) > 7$, mostrando os neurônios e os objetos, com área de influência dos neurônios, ρ limitado a 0.5. 130

Figura 6.18 – As três distâncias da *U-matrix* 132

Figura 6.19 – Representação 3D da *U-matrix* (adaptado de Ultsch, 1993a). 132

Figura 6.20 – *U-matrix* na forma 3D do SOM 10x10 apresentado na Figura 6.9. 135

Figura 6.21 – *U-matrix,* na forma de imagem bidimensional, do SOM 10x10 apresentado na Figura 6.9. 135

Figura 6.22-a – Marcadores para a *watershed* convencional (todos os mínimos locais). 141

Figura 6.22-b – Marcadores para a *watershed* escolhidos manualmente (apenas alguns mínimos regionais). 141

Figura 6.23 – Marcadores obtidos para a *U-matrix* da Figura 6.21 usando como limiar k=43. 143

Figura 6.24 – Linhas de *watershed* obtidas da *U-matrix* da Figura 6.21. 143

Figura 6.25 – Linhas de *watershed* sobrepostas a *U-matrix* original, Figura 6.21. 143

Figura 6.26 – Regiões conectadas da *U-matrix* rotuladas pelo algoritmo RCC. 144

Figura 6.27 – Rotulagem de neurônios do SOM 10 x 10 pela cópia dos códigos da *U-matrix* rotulada (Figura 6.26). 145

Figura 6.28 – Mapa 10 x 10 totalmente rotulado usando o método vizinhos mais próximos para classificar os pixels não rotulados da Figura 6.27. 146

Figura 6.29 – Mapeamento dos padrões no mapa 10 x 10 usando a informação *a priori* das classes dos padrões. 147

Figura 6.30 – Mapeamento dos padrões no mapa 10 x 10, usando a informação das classes dos padrões, sobreposto à partição do mapa obtida usando apenas os padrões. 148

Figura 6.31 – Grade do mapa 10 x 10 rotulado. Na figura todos os neurônios foram representados com o mesmo tamanho, diferenciando apenas o nível de cinza, que está relacionado ao agrupamento detectado. 149

Figura 6.32 – Grade do mapa 10 x 10 rotulado, usando a informação de número de padrões mapeados em cada neurônio para representar o tamanho da grade. 150

Figura 6.33 – Classificação dos padrões usando a classe dos neurônios vencedores. 150

Figura 7.1 – Segmento de sinal EMG extraído do grupo NOR, adquirido em contração isométrica a 5% da CVM usado para geração da matriz de dados usada nos ensaios. 154

Figura 7.2 – Padrões de disparo instantâneo das UMs identificadas no sinal da Figura 7.1. Os MUAPs agrupados pelo algoritmo de classificação, após a etapa de checagem do período refratário, são organizados em função de seus tempos de disparos dispostos em ordem crescente, compondo assim os MUAPTs válidos. 156

Figura 7.3 – Histograma mostrando a distribuição observada dos IPIs para os quatros trens de MUAPs resultantes da decomposição do sinal EMG da Figura 7.1. 156

Figura 7.4 – Formas de ondas dos MUAPs protótipos (amplitude normalizada) para os quatro MUAPTs decompostos, estimadas pela média das formas de onda de todos os picos pertencentes aos seus respectivos trens. 157

Figura 7.5 – Segmento do sinal EMG original e do sinal EMG filtrado com os picos identificados. 157

Figura 7.6 – Função densidade de probabilidade do IPI estimada versus a função observada do MUAPT #1. (taxa de identificação: ID = 0.70; IPI médio: · μ = 62.8 ms; desvio padrão: · σ = 9.4 ms, coeficiente de variação: CV = 0.15, taxa de disparo médio = 15,9 Hz). 159

Figura 7.7 – Histograma de dois trens de pulsos diferentes e o histograma resultante de suas fusões (obtido por simulação). 161

Figura 7.8 – "*Aliasing*" da média devido a dados perdidos (obtido por simulação). 163

Figura 7.9 – Variação do menor *CV* versus variação no *CV* para trens não fundidos. Valores do menor *CV* para dois trens não fundidos são mostrados em vermelho, e os valores resultantes da fusão dos dois trens (i.e., falsas classificações) são mostrados em azul. 167

Figura 7.10 – Variação do menor *CV* versus proporção de dados perdidos. Trens não fundidos em vermelho, e resultados para trens fundidos em azul. 168

Figura 7.11 – Variações do menor *CV* versus período de amostragem. 169

Figura 7.12 – Variação do menor *CV* versus razão entre IPIs médios de trens não fundidos. 170

Figura 8.1 – Parâmetros morfológicos do MUAP no domínio do tempo. 178

LISTA DE TABELAS

Tabela 2.1 – Concentrações intra e extracelulares de alguns íons para o axônio gigante da lula, a fibra muscular do sapo e eritrócitos humanos. (Guyton & Hall: Medical Physiology). 22

Tabela 6.1 – Esquema para preenchimento da U-MATRIX 133

Tabela 8.1 – Estatísticas dos parâmetros do MUAP no domínio do tempo para os grupos NOR, NMO, e MIO. 183

Tabela 8.2 – Estatísticas do modelo de ordem p, e coeficientes AR α_1 até α_{12} para os grupos NOR, NMO, e MIO. 184

Tabela 8.3 – Estatísticas das medidas espectrais AR para os grupos NOR, NMO, e MIO. 185

Tabela 8.4 – Estatísticas dos coeficientes cepstral c_1 à c_{12} para os grupos NOR, NMO, e MIO. 187

Tabela 8.5 – Média e desvio padrão do diagnóstico produzido por cada modelo de classificador para cada conjunto de características. 188

LISTA DE ABREVIATURAS

ART	=	*"Adaptative Ressonance Theory"*.
BMU	=	*"Best Match Unit"*, Neurônio vencedor.
CP	=	Componentes Principais.
CV	=	Coeficiente de Variação.
CVM	=	Contração Voluntária Máxima.
DPB	=	Diferencial Passa-baixas.
DPBP	=	Filtro Diferencial Passa-baixas Ponderado.
EMG	=	Eletromiografia; Eletromiográfico.
EMG-ARE	=	Eletromiografia de Alta Resolução Espacial.
EMGS	=	Eletromiografia de Superfície; Sinal Eletromiográfico de Superfície.
ID	=	Taxa de identificação.
IPI	=	Intervalo Interpulsos, intervalo entre dois disparos consecutivos da mesma unidade motora.
MFAP	=	Potencial de Ação da Fibra Muscular.
MIO	=	Grupo de pacientes sofrendo de Miopatias (Duchenne).
MUAP	=	Potencial de Ação da Unidade Motora.
MUAPT	=	Trem de Potenciais de Ação da Unidade Motora.
NDD	=	Filtro espacial Normal Duplo Diferencial.
NMO	=	Grupo de pacientes sofrendo com patologias do Neurônio Motor (PCs).
NOR	=	Grupo de sujeitos Normais.
PA	=	Potencial de Ação.
QV	=	Quantização Vetorial.

RCC	=	Rotulação de Componentes Conectados.
RMS	=	Valor Médio Quadrático.
RNA	=	Rede Neural Artificial.
SME	=	Sinal Mioelétrico.
SNC	=	Sistema Nervoso Central.
SOM	=	"*Self-Organizing Map*"; Mapa auto-Organizável de Kohonen.
STD	=	Desvio padrão.
SVD	=	Decomposição em Valores Singulares.
UM	=	Unidade Motora.
U-matrix	=	Matriz de distâncias unificadas, "Matriz onde os elementos são distâncias entre neurônios, calculadas no espaço de pesos".
WTA	=	"*Winner Takes All*", Vencedor leva tudo.

RESUMO

FLÔR, S.W.A. *DECOMPOSIÇÃO DE SINAIS MIOELÉTRICOS SUPERFÍCIAIS: AVALIAÇÃO NÃO-INVASIVA DE DESORDENS NEUROMUSCULARES.* SÃO CARLOS, 2003. TESE (DOUTORADO) – ESCOLA DE ENGENHARIA DE SÃO CARLOS, UNIVERSIDADE DE SÃO PAULO.

Informações sobre as características funcionais e estruturais da unidade motora (UM) são altamente relevantes em investigações fisiológicas e nos estudos clínicos das disfunções neuromusculares. A eletromiografia (EMG) é um método adequado para obtenção dessas informações. Entretanto, devido à dificuldade na separação da atividade individual de uma unidade motora das outras que estão simultaneamente ativas, seu uso em clínica prática se dá comumente através de métodos invasivos, empregando eletrodos de agulha ou fios implantados. Apesar da EMG de superfície ser não-invasiva e, portanto mais apropriada para aplicações clínicas, não é usada em clínica porque não há até o presente um método satisfatório para decomposição do sinal EMG de superfície. Um EMG de superfície é muito mais difícil de decompor devido a significante superposição dos Potenciais de Ação das UMs (MUAPs) e a relação sinal-ruído relativamente baixa, se comparada aos métodos invasivos. Defendemos que a separação da atividade individual das UMs pode ser feita de modo não-invasivo aliando-se técnicas de aquisição altamente especializadas com técnicas usadas em reconhecimento de padrões. Desenvolvemos um método para decomposição de EMGs de superfície, a partir do qual foi possível extrair características relevantes das UMs, que permitem seu uso em avaliação e diagnóstico de desordens neuromusculares.

Em nossa abordagem, o sinal EMG é inicialmente captado sob contração isométrica fraca usando eletrodos de superfície. O sinal EMG bruto passa em seguida por um filtro Diferencial Passa-Baixas Ponderado (DPBP) em série com um detector de picos, que detecta os picos de MUAPs e extrai suas formas de onda. Na seqüência, o conjunto de MUAPs extraído é classificado por uma rede neural SOM, e os MUAPS agrupados pela similaridade de suas formas de onda. No próximo passo a informação temporal dos disparos é checada, eliminando possíveis erros de classificação, e finalmente os Trens de MUAPs (MUAPTs) das UMs individuais são reconstituídos do EMG original. As estatísticas de disparos (IPI) bem como as formas de ondas dos MUAPs das respectivas UMs são então extraídas e armazenadas para estudos posteriores. Resultados preliminares obtidos com EMGs normais e patológicos, extraídos de membros superiores sob contração fraca, indicam que, o método mostrou-se apto a decompor EMGs de superfícies, além de potencial para aplicações em estudos clínicos não-invasivos de disfunções neuromusculares.

Palavras-chave: Decomposição de EMG de superfície; Disfunções neuromusculares; EMG superfície; Filtro passa-baixas diferencial; Estatísticas IPI; Mapa SOM; Potencial de ação; Rede neural artificial; Unidade motora.

ABSTRACT

FLÔR, S.W.A. *SURFACE MIOELETRIC SIGNALS DECOMPOSITION: NON-INVASIVE EVALUATION OF NEUROMUSCULAR DISORDERS.* SÃO CARLOS, 2003. THESIS (DOCTORATE) - SCHOOL OF ENGINEERING OF SÃO CARLOS, UNIVERSITY OF SÃO PAULO

Information on the functional and structural characteristics of the motor unit (MU) they are highly important in physiologic investigations and in the clinical studies of the neuromuscular dysfunctions. The electromyography (EMG) it is an appropriate method for obtaining of that information. However, due to the difficulty in the separation of the individual activity of a motor unit of the another that are simultaneously active, your use in practical clinic happen commonly through methods invasive, employing needle electrodes or implanted threads. In spite of surface EMG to be non-invasive and, therefore more appropriate for clinical applications, it is not used at clinic because there is not until the present a satisfactory method for decomposition of the surface EMG sign. A surface EMG is much more difficult of decomposing due to significant overlap of the Motor Unit Action Potentials (MUAPs) and the relationship sign-noise relatively low, if compared to the invasive methods. We defended that the separation of the individual activity of MUs can be made in way non-invasive allying highly specialized acquisition techniques with techniques used in recognition of patterns. We developed a method for decomposition of surface EMGs, starting from which was possible to extract important characteristics of MUs, which allow your use in evaluation and diagnosis of neuromuscular disorders.

In our approach, the sign EMG is captured initially under weak isometric contraction using surface electrodes. The sign EMG raw raisin soon after for a Biased Low-Pass Differential filter (BLPD) in series with a detector of peaks, that detects the peaks of MUAPs and it extracts your wave forms. In the sequence, a SOM neural network classifies the set of extracted MUAPs, and MUAPS are clustered by the similarity in your wave shape. In the next step the temporal information of the discharges is checked, eliminating possible classification mistakes, and finally the MUAPs Trains (MUAPTs) of individual MUs they are reconstituted of original EMG. The statistics of discharges (IPI) as well as the forms of waves of MUAPs of respective MUs are then extracted and stored for subsequent studies. Results preliminaries obtained with normal and pathological EMGs, extracted of superior members under weak contraction, they indicate that, the method was shown capable to decompose surfaces EMGs, besides potential for applications in clinical studies non-invasive of neuromuscular dysfunctions.

Word-key: Surface EMG Decomposition; Neuromuscular disorders; Surface EMG; Biased Low-pass differential filters; Statistics IPI; SOM Map; Action potential; Artificial neural networks; Motor unit.

CAPÍTULO 1

INTRODUÇÃO

1.1 Considerações iniciais

Sinais médicos do tipo eletromiograficos (EMG), apresentam comportamento não-determinístico, estocástico, e por vezes caótico, sendo por isso difícil à correlação direta de seu comportamento com patologias musculares (paralisias, mialgias, etc.). De forma que na maioria dos casos clínicos o médico despreza a análise destes sinais, adotando outros procedimentos, por vezes empíricos, que irão auxilia-lo no processo de tomada de decisão.

A decisão para um tratamento específico é até o momento baseada em dados subjetivos como os obtidos por exames clínicos e por avaliação visual. Isto pode resultar em um diagnóstico errôneo e assim em uma medicação incorreta, por exemplo, uma operação desnecessária. Além disso, se não adequadamente tratada, a desordem pode levar a uma disfunção postural irreversível (Meinecke et al.). Muitas cirurgias de substituição de músculo são feitas sem um critério mais preciso de avaliação do músculo que vai ser implantado, isso leva algumas vezes a resultados inferiores à expectativa do procedimento. A decisão pré-operatória deve ser baseada na informação sobre o estado dos músculos afetados, sendo que a análise de sinais eletromiográficos de superfície (EMGS) é particularmente atrativa, porque provê um acesso relativamente fácil aos processos fisiológicos que permitem ao músculo gerar força e movimento (Hermens & Freriks, 1999), (De Luca, 1993a).

O sinal EMG é em essência constituído pela somatória temporal de disparos de "trens" de potenciais de ação das unidades motoras individuais (MUAP), Figura 1.1. Uma *unidade motora* (UM) é uma entidade anatômica que consiste de um único motoneurônio, seu axônio, e as fibras musculares nele inervadas, é considerada a unidade funcional fundamental do sistema motor, visto que o sistema nervoso central (SNC) não pode controlar cada fibra muscular individualmente. Estudos neurofisiológicos têm revelado que o recrutamento de UMs é baseado em dois mecanismos: seqüência de recrutamento; e modulação da freqüência de disparo. Estes dois mecanismos são responsáveis pela produção suavemente graduada da força de saída pelo músculo, e têm sido bem estudados e documentados sob condições fisiológicas normais (Fang et al., 1997), (De Luca, 1993a). Os interesses clínicos, contudo, são mais focados no estudo do comportamento de UMs individuais em certas lesões do SNC e miopatias em geral.

Devido ao comportamento estocástico dos disparos, a extração e identificação dos trens de MUAPs via EMGs não é simples, e exige o emprego de técnicas de análise de séries temporais com dinâmica não-linear (Fang et al.,1997), (Filligoi & Felici, 1999). Existem muitos trabalhos recentemente publicados sobre técnicas que auxiliam na tarefa de interpretação do eletromiograma, desde simples inferências estatísticas sobre o sinal como freqüência mediana, valor médio quadrático (RMS) (De Luca, 1993a), coeficientes de correlação, até outras mais complexas como análise espectral, decomposição por transformadas wavelets (Fang et al., 1999a), decomposição em valores singulares (SVD) (Sun et al., 2000), e ultimamente classificação de padrões com redes neurais artificiais (RNA) (Xu et al., 2001), além de outras.

As diferentes desordens neuromusculares são freqüentemente caracterizadas por alguma mudança patológica especifica na estrutura das unidades motoras (UMs). De modo geral, as desordens neuromusculares

podem ser divididas aproximadamente em desordens musculares e neuronais. Nas desordens musculares, a disfunção é originada no próprio músculo, e durante o progresso da desordem fibras musculares individuais são sucessivamente perdidas. Já nas desordens neuronais, em contraste, a disfunção se origina fora do músculo propriamente dito, ou seja, a parte neuronal da UM é afetada. Como conseqüência, todas as fibras ao longo de uma UM não podem ser excitadas. Adicionalmente, em alguns casos um processo de reinervação toma lugar, no qual os neurônios motores de UMs ativas inervam as fibras musculares das UMs danificadas. A conseqüência é o "alargamento", ou seja, aumento em tamanho e diminuição do número, das UMs ativas remanescentes.

Essas mudanças na estrutura das UMs são refletidas por sua atividade elétrica (Buchthal & Rosenfalk, 1973). A atividade do músculo está associada com os sucessivos disparos das (UMs) individuais, conhecidos como Trens de Potencial de Ação da Unidade Motora (MUAPT). Os MUAPTs que contribuem para o sinal mioelétrico (SME) fornecem informação relativa ao comportamento temporal e a morfologia das UMs que estão ativas durante a contração muscular. Tais informações podem auxiliar no diagnóstico de várias desordens neuromusculares e no melhor entendimento dos sistemas neuromusculares sadios, patológicos, em processo de fadiga ou envelhecimento.

Os SMEs são compostos da superposição dos MUAPTs de várias UMs distintas, e o processo de obtenção dos MUAPTs a partir do SME puro é chamado de decomposição, a Figura 1.1 apresenta conceitualmente o processo de decomposição do SME, e mostra a relação entre o SME decomposto e a atividade das UMs individuais.

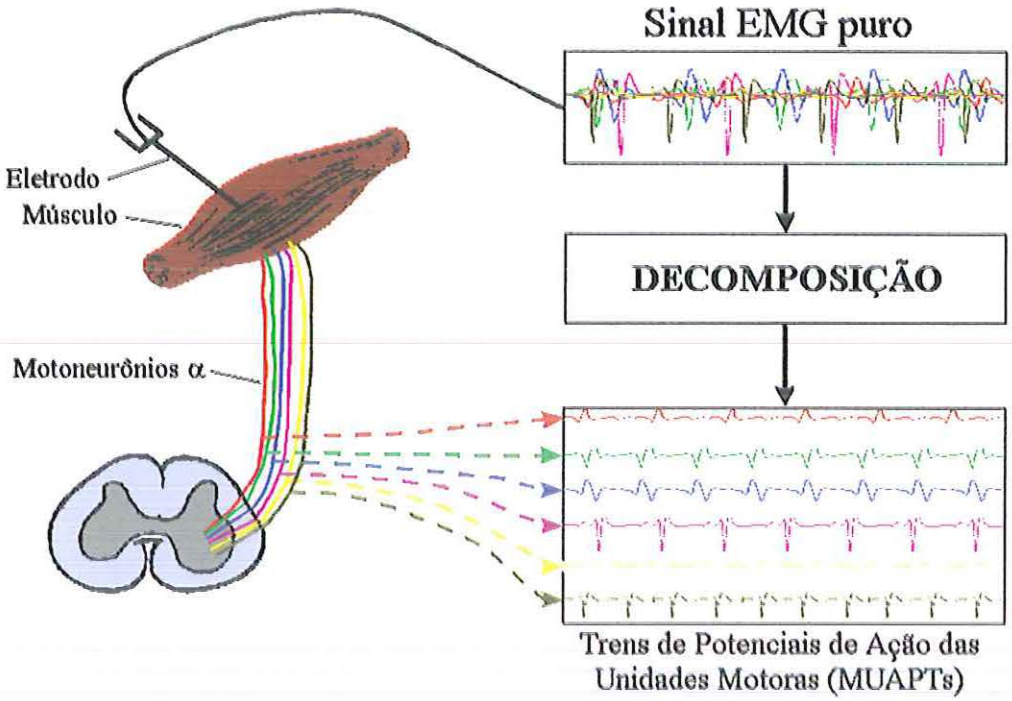

Figura 1.1 – Decomposição do sinal mioelétrico é o processo de descoberta dos MUAPTs constituintes significantes que contribuem para o sinal mioelétrico detectado, (adaptado de De Luca et al., 1982).

Através da decomposição do sinal mioelétrico (SME) em seus constituintes trens de MUAPs, medições de MUAPs individuais se tornam possíveis. A decomposição de um SME e a análise da informação resultante, envolve a aplicação de processamento de sinal e algoritmos de reconhecimento de padrão, e foram reportados pela primeira vez por De Luca e colaboradores, 1982.

Em clínica prática, a distinção entre desordens neuronais e musculares é baseada, entre outras coisas, na informação sobre a atividade elétrica individual da UM. Até o presente, estas informações são obtidas usando técnicas invasivas, através da eletromiografia (EMG) de agulha ou de fio. As metodologias convencionais para Eletromiografia de Superfície (EMGS) não são adequadas para este objetivo, devido ao efeito de filtragem passa-baixas dos tecidos entre as UMs ativas e os eletrodos na superfície da

pele, que atenuam as componentes de alta freqüência do potencial de ação, abaixo do nível de ruído. Estas componentes são perdidas e não podem ser recuperadas, portanto, informação a respeito da atividade das UMs localizadas distantes da superfície da pele é bastante limitada. Além disso, devido a baixa resolução espacial, a EMGS convencional detecta apenas o sinal superposto de um grande número de UMs, (Basmajian & De Luca, 1985). Entretanto, a distribuição de potencial gerada na superfície da pele por um estimulo muscular, contém alguma informação sobre a atividade individual da UM, mas ela é perturbada pela contribuição de outras UMs simultaneamente ativas. As atividades individuais das UMs localizadas próximas à superfície da pele são detectáveis de forma não invasiva melhorando-se a resolução espacial do sistema de aquisição. Isto pode ser realizado, quando arranjos de eletrodos são usados em combinação com procedimentos de filtragem espacial (vide Capítulo 4), (Broman et al., 1985), (Masuda et al., 1985), (Merletti & De Luca, 1989), (Reucher et al., 1987) e (Schneider et al. 1989).

Apesar da baixa resolução espacial a EMGS convencional é largamente utilizada como um procedimento não invasivo, pelo fato de refletir apenas a atividade composta de um grande número de UMs. A EMGS convencional é usada para obter informação global sobre o músculo tais como, padrão de coordenação de diferentes músculos, tempo e intensidade da ativação muscular superficial, com aplicações bem fundamentadas em biomecânica, biofeedback, e reabilitação, não sendo, contudo adequada para detecção da atividade individual de UMs.

Técnicas invasivas, como eletrodos de agulha ou de fios, têm alta resolução espacial, e permitem a detecção da atividade individual das UMs. Todavia apresentam algumas desvantagens: o desconforto/dor que causam as inserções da agulha ou do fio; requerem a supervisão médica; e podem trazer riscos de infecção. A repetibilidade das medidas é pobre, os fios tendem a

migrar com o tecido muscular durante a contração, e o monitoramento em longo prazo quase não é possível, sendo este método difícil de usar na prática.

A distribuição de potencial gerada na superfície da pele pela atividade muscular contém informação sobre a atividade individual das unidades motoras. Conseqüentemente, estas atividades tornam-se detectáveis não-invasivamente quando a resolução espacial é melhorada. O primeiro passo nesta direção foi o desenvolvimento de eletrodos ativos, que permitem a detecção de sinais de amplitude muito baixa. Esta técnica torna possível reduzir a distância intereletródica, e desse modo melhorar a resolução espacial do arranjo de gravação. Outra abordagem é baseada em sistemas bipolares concêntricos, que consistem de um eletrodo central rodeado por um anel concêntrico. O sistema concêntrico, bem como o bipolar com distância intereletródica na faixa de alguns milímetros, permitem a detecção não invasiva da atividade de UMs individuais, mas este procedimento é limitado a 20% da Contração Voluntária Máxima (CVM) do músculo. Além deste nível de força, muitas UMs são ativadas, formando um padrão de interferência complexo, enquanto que a decomposição do sinal no tempo para isolar um simples potencial de ação de UM é cada vez mais difícil.

A detecção não invasiva da atividade de simples UMs, até mesmo durante a Contração Voluntária Máxima (CVM) do músculo, tornou-se possível pela primeira vez quando arranjos de eletrodos foram usados em combinação com o processamento usando um filtro espacial bidimensional, denominada EMG de Alta Resolução Espacial (EMG-ARE) por (Rau & Disslhorst-Klug, 1997), o que abriu o acesso ao estudo e análise de uma variedade de parâmetros das UMs isoladamente.

Existem alguns métodos notáveis para decomposição automática do SME, todos eles voltados para a EMG de agulha, tais como o ADEMG (McGill et al., 1989), e o NNERVE (Hassoun et al., 1994). Apesar da EMG de

superfície ser não invasiva e por conseguinte mais apropriada para aplicações clínicas, ela quase não é usada em investigações clínicas, ou é apenas usada como um complemento da EMG de agulha, quando o acesso aos padrões de coordenação e intensidade da ativação muscular são requeridos. Isto se deve a não existência até o presente de um método satisfatório para decomposição automática do EMG de superficie. O EMG de superfície é muito mais dificil de decompor devido à significante superposição dos MUAPs, e ainda a relativamente baixa relação sinal-ruído, mesmo durante contração fraca.

Em estudos clínicos e investigações fisiológicas utilizam-se as estatísticas do Intervalo Interpulsos (IPI), ou seja, o tempo entre dois disparos sucessivos da mesma UM, e as propriedades da forma de onda do MUAP. Estes parâmetros são obtidos usando procedimentos de decomposição, no qual um EMG é separado em seus constituintes trens de MUAPs, sobre os quais há farta literatura, (Andreasen & Rosenfalck, 1978), (Lefever & De Luca, 1982), (Gath & Stalberg, 1982), (Gerber et al., 1984), (Mc Gill et al., 1985), (Broman, 1988), (Stashuk & De Bruin, 1988), (Fuglevand et al., 1992), (Hassoun et al., 1994).

Lefever & De Luca, (1982), desenvolveram um algoritmo para decompor um sinal EMG em seus constituintes MUAPs durante contração forte. Na aquisição do sinal foi usado um eletrodo especialmente projetado, que consistiu de um eletrodo de agulha de três canais, possibilitando a gravação do sinal a partir de três perspectivas diferentes. Para identificar e classificar os MUAPs usaram um método conhecido como "template matching", ou seja, as formas de ondas dos MUAPs candidatos eram comparadas com um gabarito "template", e uma medida de correlação dava o grau do casamento "matching" entre o gabarito pré-definido e a forma do MUAP candidato. Em seguida, possíveis erros de classificação na fase de emparelhamento podiam ser detectados através das estatísticas de disparos dos

MUAPs já classificados. Puderam ser extraídos até oito MUAPTs, adquiridos com nível de até 80% da CVM, o algoritmo requeria interação com o operador e consumia tempo demais para ser usado clinicamente.

Um algoritmo para decomposição automática, ADEMG, foi inicialmente desenvolvido e aplicado clinicamente por McGill et al., (1985; 1989). Este algoritmo usou o método "adaptative template matching", com um algoritmo de alinhamento específico para identificar e extrair simultaneamente os MUAPs ativos de um EMG de agulha. Vários MUAPs puderam ser extraídos automaticamente sem entrada e ajuste do usuário. As formas de onda dos MUAPs foram estimadas pela ponderação de um grande número de ocorrências após cancelamento de superposição. Foi alegado que até 15 MUAPTs puderam ser extraídos de EMGs adquiridos com nível de até 30 % da CVM.

Uma abordagem baseada em uma Rede Neural Artificial (RNA) para decomposição automática do sinal EMG foi desenvolvida por Hassoun et al., (1994). Neste método, um classificador baseado numa rede perceptron multicamadas, chamado de NNERVE (Neural Network Extraction of Repetitive Vector for Electromyography) foi treinada usando um algoritmo de aprendizagem baseado no método de retropropagação pseudo-não-supervisionado para descobrir as características de MUAPs diferentes, e realizar sua classificação. NNERVE foi aplicado em sinais EMG gravados por eletrodos de agulha convencionais. Diferentemente dos métodos tradicionais, uma RNA não requer suposições analíticas rígidas ou causais, ela tem a habilidade de construir seu conhecimento por meio de auto-aprendizagem. A partir de sessões de treinamento a RNA pode descobrir as características dos diferentes MUAPs, em resposta a um conjunto de amostras de MUAPs usados para treinamento. NNERVE mostrou uma alta performance e robustez sobre sinais variando amplamente dentro do espaço característico definido. Essa

abordagem baseada em perceptrons multicamadas apresenta algumas limitações, a saber: (1) o treinamento pode não convergir para uma solução ótima, e (2) a classificação é muito sensível à seleção das amostras de treinamento. A performance de classificação pode se degradar significantemente se existirem algumas amostras inválidas no conjunto de treinamento. Amostras inválidas tais como superposições não podem ser evitadas na prática. Para resolver esses problemas, um modelo de rede neural com aprendizagem não-supervisionada tal como os Mapas Auto-Organizáveis de Kohonen (SOM), proposta neste trabalho, pode ser adotada.

1.2 Justificativa do trabalho

Até o presente, quase todos os métodos de decomposição têm sido desenvolvidos para EMGs invasivos (de agulha e/ou fios). Apesar da EMG de superfície ser não-invasiva e melhor aceita pelos pacientes, especialmente por crianças, a dificuldade para identificar MUAPs individuais a partir dos EMGs de superfície tem limitado significantemente suas aplicações. Dois fatores principais tornam a decomposição dos EMGs de superfície difícil: (1) a baixa relação sinal-ruído; e (2) a significante superposição de MUAPs.

Nosso objetivo, portanto é desenvolver um método de decomposição automático para sinais mioelétricos superficiais que supere estas limitações, propiciando seu uso clínico em diagnóstico e avaliação de desordens neuromusculares.

Nossa abordagem para a decomposição dos EMGs se baseia em um filtro Diferencial Passa-baixas Ponderado (DPBP) e uma rede neural baseada no Mapa Auto-Organizável de Kohonen (SOM) em arranjo bidimensional, para estimar as formas de onda dos MUAPs e os parâmetros das estatísticas de disparos dos EMGs de superfície. Nosso esquema de decomposição pode ser dividido em quatro etapas:

1. Processar o EMG puro e gerar os vetores de treinamento;
2. Treinar a rede de Kohonen;
3. Identificar os trens de MUAPs do EMG usando a rede treinada;
4. Extrair as formas de onda dos MUAPs e as informações de disparo.

No primeiro passo, o EMG de superfície é gravado e pré-filtrado. Um detector de picos é então usado para detectar os candidatos a MUAP. As formas de onda e as posições (tempo de ocorrência dos disparos), obtidas do detector de picos são usadas para formar os vetores de treinamento. Todos os vetores formam um conjunto de treinamento. Esta parte tem importância vital em todo o esquema de decomposição.

No segundo passo, a rede de Kohonen deverá aprender a reconhecer possíveis agrupamentos contidos nos conjuntos de treinamento. Visto ser comum a ocorrência de sinal de fundo acrescido de ruído misturado aos candidatos a MUAPs, além ainda de amostras inválidas e/ou corrompidas misturadas aos conjuntos de treinamento, a aprendizagem deverá ser realizada em vários passos iterativos sobre os conjuntos de treinamento.

Após a rede ter sido treinada, uma etapa de identificação é usada para reconhecer os trens de MUAPs. Como na etapa de treinamento, os vetores dos candidatos a MUAPs são alimentados na rede, mas os pesos da rede não são ajustados. A saída da rede (resultados que determinam quais agrupamentos da entrada foram reconhecidos como candidatos a MUAPs pertencentes à mesma classe) é então armazenada para posterior processamento. Após os candidatos a MUAPs terem sido classificados em seus vários agrupamentos, o procedimento seguinte examina seus padrões de disparos verificando se o mesmo corresponde a um MUAP válido. Várias tarefas são realizadas para melhorar a precisão na classificação dos trens de MUAPs válidos, se um trem de MUAP é aceito como válido, as estatísticas de

disparos e a forma de onda são então extraídas. O diagrama de blocos da Figura 1.2 dá uma visão geral do sistema de decomposição, mostrando todas as etapas envolvidas no processo, desde a entrada do sinal mioelétrico bruto, até a saída dos parâmetros temporais e morfológicos das UMs.

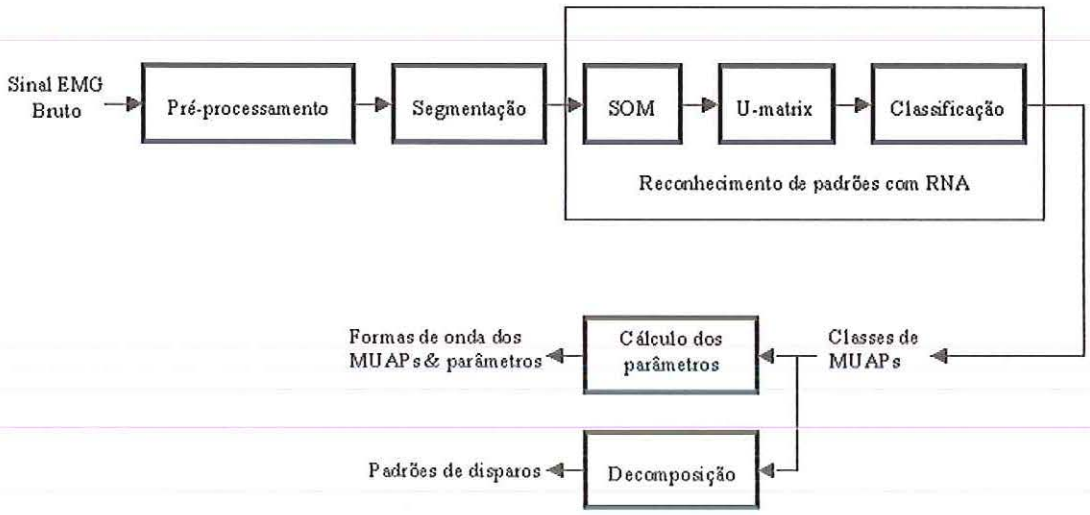

Figura 1.2 – Diagrama de blocos do sistema de decomposição.

A partir do método de decomposição desenvolvido, os sinais EMGS de três grupos distintos: sujeitos normais (NOR), pacientes sofrendo com patologias do neurônio motor (NMO), e pacientes com miopatias (MIO), foram decompostos, sendo extraídas as estatísticas do Intervalo Interpulsos (IPI), e as propriedades morfológicas do MUAP. A partir das características morfológicas dos MUAPs extraídas, realizamos um estudo clínico que poderá servir de base para a elaboração de um sistema suporte de decisão para o clínico, cujo objetivo é prover informação útil para avaliar desordens neuromusculares bem como auxiliar no diagnóstico de patologias neuromusculares.

1.3 Disposição do trabalho

Partindo das considerações expostas, este trabalho foi dividido em três partes: a primeira consiste em uma introdução teórica e uma revisão bibliográfica a respeito da base teórica envolvida no sistema computacional desenvolvido; a segunda contém a explicação sobre as técnicas desenvolvidas, bem como os resultados obtidos e discussões acerca deles; por fim na terceira parte, apresenta-se um estudo clínico realizado a partir das características extraídas pelo sistema de decomposição desenvolvido, ilustrando sua utilidade na produção de diagnósticos e avaliação de desordens neuromusculares. Apresenta-se aqui um breve resumo de cada capítulo, a fim de facilitar a localização dos assuntos abordados:

- **Capítulo 2:** descreve os fundamentos teóricos da EMG, a fisiologia da unidade motora, os mecanismos de geração do impulso nervoso e da contração muscular.
- **Capítulo 3:** aborda os efeitos dos tecidos subcutâneos sobre os sinais detectados na superfície da pele, as vantagens e limitações das técnicas de EMG de superfície com respeito a técnicas invasivas, e as possibilidades de compensação do efeito dos tecidos subcutâneos.
- **Capítulo 4:** Os vários passos envolvidos na decomposição do sinal EMG são descritos e aspectos importantes relativos a cada um desses passos são discutidos. São apresentados ainda alguns usos para os resultados da decomposição, em diagnóstico, gerência de desordens neuromusculares e na pesquisa avançada.
- **Capítulo 5:** Inicia a descrição dos métodos desenvolvidos durante essa pesquisa, mostrando a aplicação de técnicas de aquisição e geração dos conjuntos de treinamento, e apresentando os resultados obtidos com essas técnicas.

- **Capítulo 6:** descreve a ferramenta básica usada para a detecção dos agrupamentos de MUAPs, o SOM "*Self-Organizing Maps*". Fornecendo os fundamentos para aplicação do SOM nos problemas de classificação automática de MUAPs.
- **Capítulo 7:** mostra e discute os resultados obtidos com as técnicas para segmentação e agrupamento dos MUAPs, além de testes para avaliação dos resultados da decomposição.
- **Capítulo 8:** apresenta um estudo clínico realizado a partir das características morfológicas dos MUAPs extraídas pelo sistema de decomposição de três grupos distintos, sendo um de controle e dois patológicos.
- **Capítulo 9:** apresenta as considerações finais do trabalho.
- **Capítulo 10:** relaciona as referências bibliográficas utilizadas no trabalho.

CAPÍTULO 2

BASES ELETROFISIOLÓGICAS DA EMG

2.1 Breve Histórico

Em 1791, Luigi Galvani, estudando preparações de pernas de rãs, demonstrou de forma pioneira que a estimulação elétrica é capaz de provocar contração muscular e que há produção de corrente elétrica durante a contração do músculo. Como acreditava ser um fenômeno natural, ele a denominou de "corrente animal". Em 1793, estimulado pela descoberta de Galvani, Volta observou que a contração muscular descrita era resultado da estimulação elétrica artificial provocada pela colocação de duas placas de metais diferentes.

Em 1851, Schiff observou pela primeira vez potenciais de fibrilações em músculo desnervado da língua de um cão. Ainda no século 19 e início do século passado, vários outros autores confirmaram o achado de fibrilações em músculos desnervados. No entanto, a atividade funcional da unidade motora (UM) e o valor da avaliação eletromiográfica muscular foram descritos pela primeira vez por Denny-Brown em 1929 e por Adrian e Bronk no mesmo ano. Estes últimos inventaram o eletrodo de agulha coaxial, que tornou bem mais fácil as pesquisas neste campo. Posteriormente, vários autores observaram e confirmaram estes achados, mas foram Weddel, Feinstein e Pattle, em 1944, que demonstraram sua importância clínica.

O mecanismo de geração do potencial de ação foi elucidado por Hodgkin e Huxley na década de 1950, em uma série de trabalhos com o

axônio gigante da lula (um axônio particularmente grosso, com meio milímetro ou mais de diâmetro). Eles receberam o prêmio Nobel de medicina e fisiologia por esse trabalho.

A partir de então, inúmeros trabalhos têm sido desenvolvidos e apresentados, ampliando cada vez mais a utilidade da eletroneuromiografia, tanto nas pesquisas fisiológicas, como no diagnóstico de patologias neuromusculares.

2.2 Fundamentos da Eletromiografia

No movimento e locomoção humanos a contração voluntária do músculo é iniciada pela excitação eletrofisiológica de um conjunto de *unidades motoras* (UMs). A eletromiografia (EMG) é um procedimento bem estabelecido para o estudo da função muscular, desde que ela permite detectar e visualizar o sinal eletrofisiológico gerado pelo músculo durante a excitação. A partir do qual torna-se possível obter informação sobre a estrutura e as características funcionais das UMs, que são altamente relevantes para o diagnóstico de desordens neuromusculares, (Figura 2.1).

A unidade motora (UM) é formada pelo segundo neurônio motor com seu corpo celular na medula espinhal, seu axônio, as junções mioneurais e as fibras musculares inervadas por este axônio. Portanto, a EMG se baseia no estudo da fisiologia da unidade motora, sendo capaz de diagnosticar ou de auxiliar no diagnóstico de enfermidades que afetem os seus componentes, tais como as neuropatias, as mielopatias, as radiculopatias, os distúrbios das junções neuromusculares, etc, (Figura 2.1).

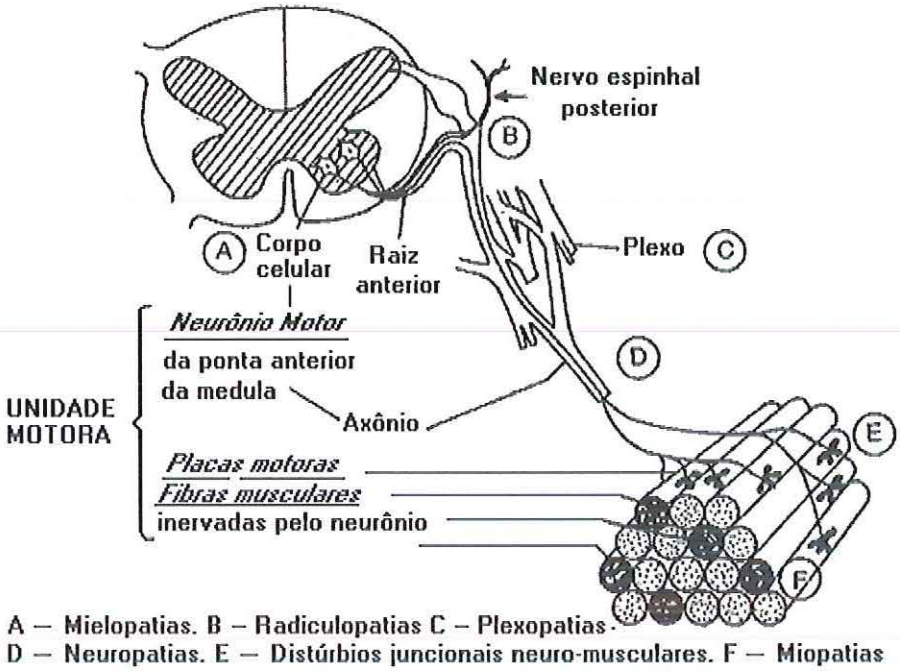

Figura 2.1 – A Unidade Motora e o diagnóstico eletroneuromiografico. O conjunto formado por um motoneurônio alfa e as fibras musculares estriadas dele dependentes constituem uma unidade motora.

A forma de onda registrada por um eletrodo intramuscular durante a descarga de uma UM é conhecida como Potencial de Ação da Unidade Motora (MUAP) (Figura 2.2), Basmajian & De Luca, (1985). Durante uma contração voluntária, as UMs disparam repetidamente, gerando Trens de Potenciais de Ação da Unidade Motora (MUAPT). O sinal gravado, chamado eletromiograma (EMG), é constituído de uma superposição de trens de MUAPs de todas UMs que tem fibras na vizinhança do eletrodo.

Mudanças no nervo ou no músculo, tais como em estados patológicos ou em estados de fadiga, alteram a amplitude, duração e forma de onda dos MUAPs, e conseqüentemente do EMG. Sendo a UM a menor unidade de excitação e contração, informação mais detalhada sobre as características do músculo, como anatomia funcional, difusão da excitação ou padrão de inervação, pode ser obtida de um simples MUAP. Assim a análise do MUAP fornece informação sobre a unidade motora e suas alterações, sendo

útil no diagnóstico de desordens musculares, controle motor, ergonomia, cinesiologia, etc.

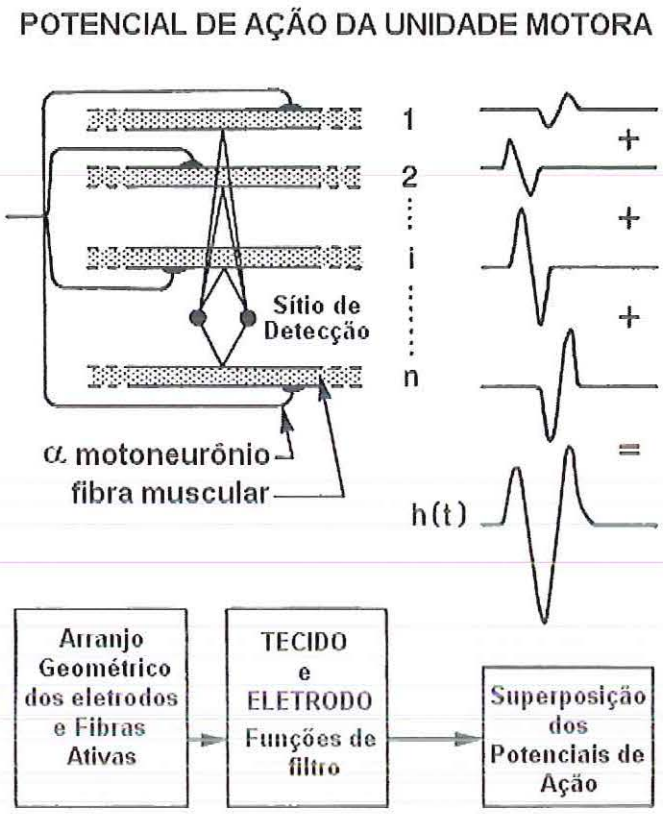

Figura 2.2 - Um MUAP é composto do somatório dos potenciais de ação das fibras musculares (MFAP) componentes da UM. A localização da fibra muscular relativa ao eletrodo, a área superficial, a configuração do eletrodo e o diâmetro da fibra afetam grandemente esta contribuição. MUAPs para uma UM em particular variam devido a variações aleatórias no inicio dos MFAPs e a diferentes velocidades de condução do MFAP (Adaptado de Basmajian & De Luca, 1985).

Investigações clínicas sobre a atividade isolada da unidade motora (UM), têm usado comumente métodos invasivos empregando agulhas ou fios, tais técnicas invasivas têm alta resolução espacial, o que as torna adequadas para a detecção da atividade isolada da UM. Os métodos convencionais de EMG de superfície (EMGS), devido a sua baixa resolução espacial, detectam a superposição de múltiplos MUAPs, gerados por um grande número de UMs. Sendo em conseqüência restritos a aplicações onde são de interesse informações globais sobre o músculo, como por exemplo, o padrão de coordenação de diferentes músculos.

Apesar disso a EMGS é largamente usada como um procedimento não invasivo, para obter informação sobre o tempo e a intensidade da ativação de músculos superficiais, com aplicações bem fundamentadas em biomecânica biofeedback, e reabilitação. A EMGS reflete a atividade eletrofisiológica do músculo, quando uma população de fibras musculares excitadas, como fontes elétricas, gera um campo de potencial na superfície da pele, formando o contorno de um volume condutor.

2.3 Bases Eletrofisiológicas da EMG

A eletricidade é um processo natural em nosso organismo e está envolvida na função específica de certas células especiais no cérebro e nos músculos estriados e lisos. Cada padrão de luz, som, calor, dor, cada piscar de olhos, estalar de dedos, cada pensamento, se traduz em uma seqüência de pulsos elétricos. Como isso acontece? Bem, vamos aprender como ele gera eletricidade, a codifica e a conduz.

As células nervosas possuem propriedades similares às outras células em muitos aspectos: elas se alimentam, respiram, passam por processos de difusão e osmose em suas membranas, etc., mas diferem em um aspecto importante: elas processam informação. A habilidade das células nervosas processarem informação depende de propriedades especiais da membrana do neurônio, a qual controla o fluxo de substâncias ao lado interno da célula (íons sódio, cálcio, potássio, etc).

Os neurônios não existem isoladamente: eles também se conectam uns aos outros formando as chamadas cadeias neuronais, as quais transmitem informações a outros neurônios ou músculos. Por essas cadeias caminham os impulsos nervosos. Dois tipos de fenômenos estão envolvidos no processamento do impulso nervoso: elétrico e químico. Os eventos elétricos

propagam um sinal dentro de um neurônio, e o químico transmite o sinal de um neurônio a outro ou a uma célula muscular.

Para entender como as células nervosas podem ser excitadas e transmitir esta excitação a outras partes do sistema nervoso, músculos e glândulas, primeiro temos que entender o papel dos íons e da água, porque eles são muito importantes para os chamados processos de membrana, isto é, funções que ocorrem na membrana celular. As citações e descrições a seguir foram em sua maioria extraídas e adaptadas do livro Medical Physiology, Guyton & Hall.

Os seres humanos têm aproximadamente 56% de sua constituição formada por líquidos. Estes líquidos estão situados dentro e fora das células, formando o compartimento intra e extracelular, que são separados pela membrana celular. Dentro dos líquidos intra e extracelulares encontramos uma série de elementos que possuem carga elétrica negativa ou positiva, que são os íons. Na EMG os íons mais importantes são os íons sódio, cloro, cálcio, potássio e o magnésio.

Os íons estão distribuídos entre os compartimentos intra e extracelulares em quantidades distintas, havendo predominância de sódio, cloro e cálcio no exterior e de potássio e magnésio no interior. Esta diferença iônica entre os dois meios depende de um gradiente de pressão, de um equilíbrio eletroquímico e de um gradiente de concentração. A diferença na composição iônica entre os dois lados da membrana afeta as propriedades elétricas das células. As diferenças no potencial e na concentração de íons entre os dois lados da membrana estão relacionadas, de maneira que mudanças no potencial podem resultar em mudanças na concentração de íons e vice-versa. A relação entre o **potencial de repouso** e a concentração de íons é controlada pela membrana (Figura 2.3).

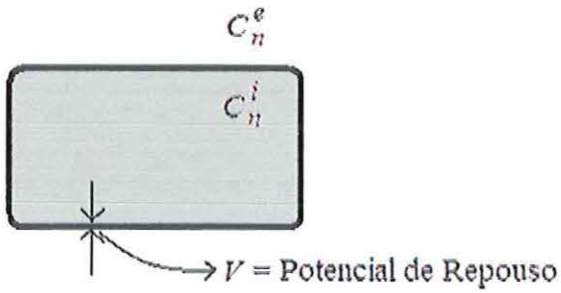

Figura 2.3 – Diferença de potencial gerada na membrana celular devido às diferenças nas concentrações iônicas entre os meios intra e extracelular, as quais são mantidas constantes no repouso.

A membrana celular, que tem uma espessura de 75 a 110 Angstrons, possui estrutura lipoprotéica, isto é, possui duas camadas de lipídios e entre elas uma camada de proteínas (Figura 2.4). Estas proteínas podem ter varias funções, tais como função de canal, enzimática, de bomba, estrutural, receptora, etc.

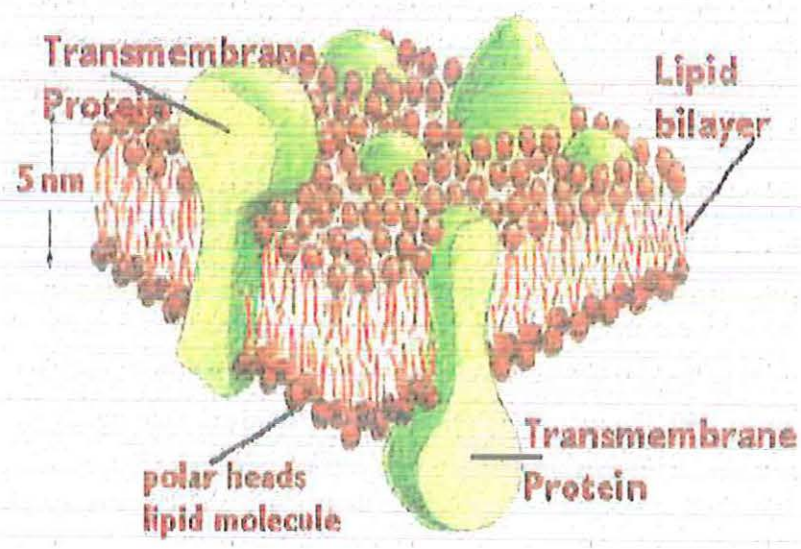

Figura 2.4 – Membrana celular, (Guyton & Hall: Medical Physiology).

Algumas proteínas atravessam a membrana de um lado ao outro, formando canais ou poros, que são utilizados pelos íons para passar através da membrana nos dois sentidos. Os poros podem alterar sua conformação sob

controle elétrico ou químico, de maneira que o fluxo iônico pode ser regulado: a **permeabilidade** de uma membrana a um dado íon é controlada pelas condições elétricas e químicas do ambiente no qual a célula está imersa (Figura 2.5).

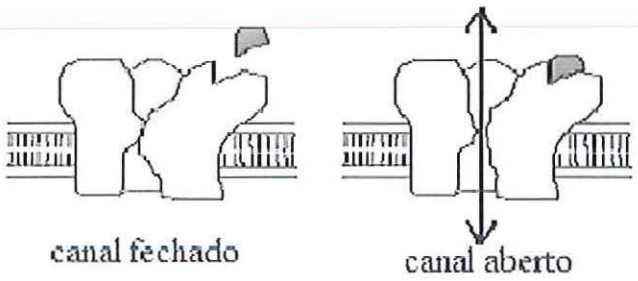

Figura 2.5 - Ilustração do processo de abertura de um canal iônico provocado pela alteração conformacional de uma proteína por sua ligação com uma substância ligante.

No estado de repouso existe uma diferença de potencial elétrico entre o lado de fora e o lado de dentro da membrana, o potencial de repouso. Definindo-se o zero de potencial no lado de fora da célula, o seu lado de dentro está, em geral, a um potencial entre –50 e –90 mV. Portanto, a face interior da membrana está a um potencial elétrico negativo em relação à face exterior.

Além da diferença de potencial elétrico, também existem diferenças nas concentrações de alguns íons entre os dois lados da membrana neuronal, as quais são mantidas constantes no repouso. O citoplasma tem uma maior concentração de íons de potássio em relação ao exterior e uma menor concentração de íons de sódio em relação ao exterior (a tabela abaixo dá os valores das concentrações de alguns íons, dentro e fora da célula, para algumas células selecionadas, Tabela 2.1).

Tabela 2.1 – Concentrações intra- e extracelulares de alguns íons para o axônio gigante da lula, a fibra muscular do sapo e eritrócitos humanos. (Guyton & Hall: Medical Physiology).

Concentração (mmol/L)							
Íon	Lula			Sapo		Humano	
	Citoplasma	Sangue	Água Salgada	Citoplasma	Plasma	Citoplasma	Plasma
K^+	400	20	10	124	2,25	150	5,35
Na^+	50	440	460	10,4	109	12 – 20	144
Cl^-	40 – 150	560	540	1,5	77,5	73,5	111
Ca^{++}	0,0001	10	10	4,9	2,1	–	6,4
Mg^{++}	10	54	53	14,0	1,25	5,6	2,14

Um neurônio concentra K^+ e expele Na^+. Um dos mecanismos que mantém este desequilíbrio é a chamada **bomba de sódio-potássio**, um complexo de moléculas protéicas grandes que, em troca de energia metabólica (hidrólise de ATP), transporta sódio para fora da célula e potássio para dentro dela (a cada três íons Na^+ levados para fora, dois íons K^+ são bombeados para dentro). Esse mecanismo atua na manutenção do **potencial de repouso** e na **repolarização celular**, sendo esta é uma das razões para o alto consumo energético das células nervosas.

Podemos estudar o comportamento de uma célula excitável, muscular ou nervosa, aplicando-lhe um estímulo elétrico, e observando sua resposta. Para fazer passar corrente através da membrana insere-se um microeletrodo na célula nervosa, como a membrana celular possui uma certa resistência à passagem de corrente elétrica, a injeção de corrente provoca, pela lei de Ohm (V=R.I), uma variação no potencial elétrico através da membrana. Desta maneira pode-se controlar o potencial de membrana de uma célula, pelo menos nas vizinhanças do eletrodo.

Quando o potencial de membrana alterado pela injeção de corrente fica mais negativo do que o potencial de repouso, diz-se que a célula está

hiperpolarizada. Quando o potencial de membrana fica menos negativo (mais próximo de zero), diz-se que a célula está despolarizada.

Injetando-se corrente numa célula de maneira a hiperpolarizá-la, o que se nota são respostas cujas formas se parecem muito com as dos pulsos de entrada (com as bordas arredondadas, pois a resposta da célula não é instantânea devido à **capacitância da membrana**, Figura 2.6).

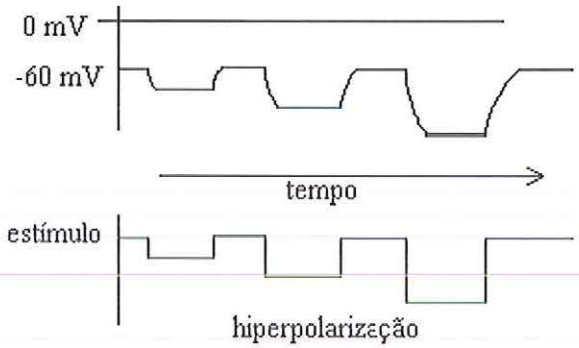

Figura 2.6 – Resposta de uma célula nervosa a estímulos de corrente.

Quando a corrente injetada provoca despolarização, o potencial de membrana segue outro tipo de comportamento. Inicialmente, à medida que os pulsos de corrente despolarizante aumentam de intensidade, a variação na voltagem aumenta gradualmente como no caso dos pulsos hiperpolarizantes. Porém, quando um valor crítico de corrente despolarizante injetada é atingido, ocorre uma grande e súbita variação na voltagem, levando o potencial de membrana a tornar-se positivo (algumas dezenas de milivolts acima do zero) por mais ou menos meio milissegundo, voltando a cair para valores negativos, próximos do potencial de repouso, em seguida. Este enorme e repentino aumento no potencial de membrana é denominado **potencial de ação** (PA), também chamado de disparo (pois ele se propaga ao longo do axônio como um pulso solitário, Figura 2.7).

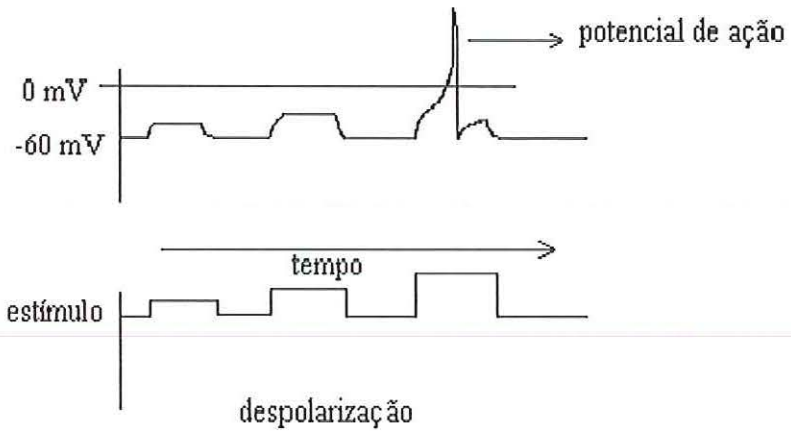

Figura 2.7 – Geração do potencial de ação.

Existe um limiar para que o valor da corrente injetada cause um potencial de ação. Abaixo do limiar não há potencial de ação, apenas despolarizações graduadas do potencial de membrana, proporcionais à corrente injetada. Já correntes injetadas com valores acima do limiar provocam o aparecimento de um potencial de ação, "**lei do tudo ou nada**".

A forma de um potencial de ação é uma característica de cada neurônio, sendo sempre igual a cada novo disparo, não dependendo do valor da corrente despolarizante injetada.

Um breve período após a geração de um potencial de ação não é possível gerar um outro, independentemente do valor da corrente injetada; é como se o limiar de corrente para a geração de um potencial de ação fosse infinito. Este período é chamado de **período refratário absoluto**.

Por um período um pouco mais longo já é possível gerar potenciais de ação, mas as correntes injetadas têm que ter valores maiores do que o inicial de corrente. Durante esse período, o limiar para geração de um potencial de ação fica acima do valor normal, indo de um valor muito grande no início do período até o valor normal no fim dele. Este período é chamado de **período refratário relativo**.

O potencial de membrana para o qual os fluxos de um íon para dentro e para fora de uma célula, causados pelas diferenças de concentração e de potencial elétrico, se igualam, resultando num equilíbrio dinâmico, é dado pela **equação de Nernst**,

$$V = \frac{RT}{zF} \ln \frac{[C]_{fora}}{[C]_{dentro}}, \qquad (2.1)$$

onde R é a constante dos gases (8,314 J/K.mol), T é a temperatura absoluta (K), z é a valência do íon (adimensional), F é a constante de Faraday (9,648x10$_4$ C/mol) e [C] é a concentração do íon.

A equação de Nernst descreve o potencial de equilíbrio para o caso em que apenas um íon pode passar através da membrana, ou seja, quando há apenas um tipo de canal iônico.

Quando temos mais íons presentes, com diferentes gradientes de concentração através da membrana e vários tipos de canais iônicos seletivos a esses íons, o potencial de equilíbrio depende das permeabilidades relativas da membrana a esses íons. Neste caso, o potencial de equilíbrio é dado pela **equação de Goldman-Hodgkin-Katz** (GHK).

Para uma célula permeável a K^+, Na^+ e Cl^- a equação de GHK nos dá:

$$V = \frac{RT}{F} \ln \frac{[K^+]_{fora} + (P_{Na}/P_K)[Na^+]_{fora} + (P_{Cl}/P_K)[Cl^-]_{dentro}}{[K^+]_{dentro} + (P_{Na}/P_K)[Na^+]_{dentro} + (P_{Cl}/P_K)[Cl^-]_{fora}}, \qquad (2.2)$$

Tal sistema aliado à busca incessante de um equilíbrio eletroquímico por parte de cada íon, gera um **potencial de repouso** (de

membrana) que basicamente nada mais é que a média ponderada entre os potenciais de equilíbrio iônico, sobretudo do Na e K.

Estudos sobre a transmissão do impulso nervoso, realizados por Hodgkin, Huxley e Katz, demonstraram que a propagação do impulso nervoso coincide com mudanças súbitas na permeabilidade da membrana do axônio para os íons sódio e potássio. Quando se inicia o impulso nervoso, que na maioria das vezes se origina no corpo celular em resposta às sinapses dendríticas, a diferença de potencial através da membrana do axônio é diminuída localmente. Imediatamente adiante da região eletricamente alterada, na direção de propagação do impulso nervoso, se abrem canais na membrana para permitir que os íons sódio penetrem no axônio (Figura 2.8).

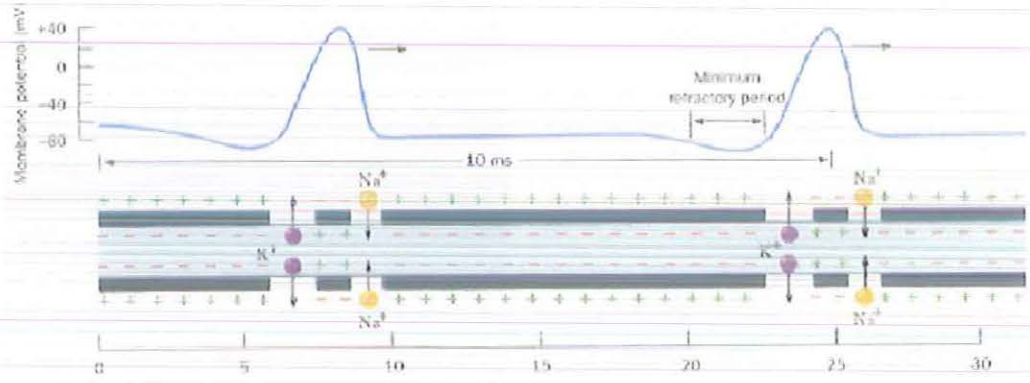

Figura 2.8 – A propagação do impulso nervoso ao longo do axônio, mostrando locais ricos em canais de sódio e potássio sensíveis à voltagem, na membrana plasmática. Nos locais assinalados pelas setas está ocorrendo despolarização maior que 100 mV, seguida de repolarização, ou seja, um potencial de ação representado na parte de cima da figura. (Fig. 34.112 – Voet)

O processo é auto-estimulado, ou seja, a entrada de sódio através da membrana abre mais canais e faz com que se torne mais fácil a entrada dos íons seguintes. Os íons sódio que entram modificam o potencial interno da membrana de negativo para positivo. Os canais de sódio se fecham rapidamente e outros canais se abrem para permitir a saída dos íons potássio para fora da célula, restabelecendo a voltagem ao seu valor de repouso. Uma

vez iniciada a propagação do estímulo ele irá se propagar ao longo da fibra, em velocidade constante, sem reduzir a amplitude do potencial de ação. Isto permite a fibra conduzir informações de um ponto a outro, por longas distancias.

Nas fibras mielínicas, em torno de 96% do total das fibras do corpo humano, a condução se faz de forma especial. Estas fibras têm a sua membrana revestida de mielina, um tipo de lipoproteína rica em fosfolipídios, como uma bainha que as envolvem. Por causa de sua característica isolante, a bainha de mielina permite uma condução mais rápida do impulso nervoso. A intervalos regulares de aproximadamente dois mm a membrana fica exposta, formando nódulos, onde se encontram os canais de sódio e potássio. Nestas fibras a onda de despolarização se propaga nos dois sentidos, pulando de um nódulo a outro, em um fenômeno conhecido como "condução saltatória". Isto faz com que a condução nervosa seja mais rápida nas fibras mielinizadas que nas amielínicas.

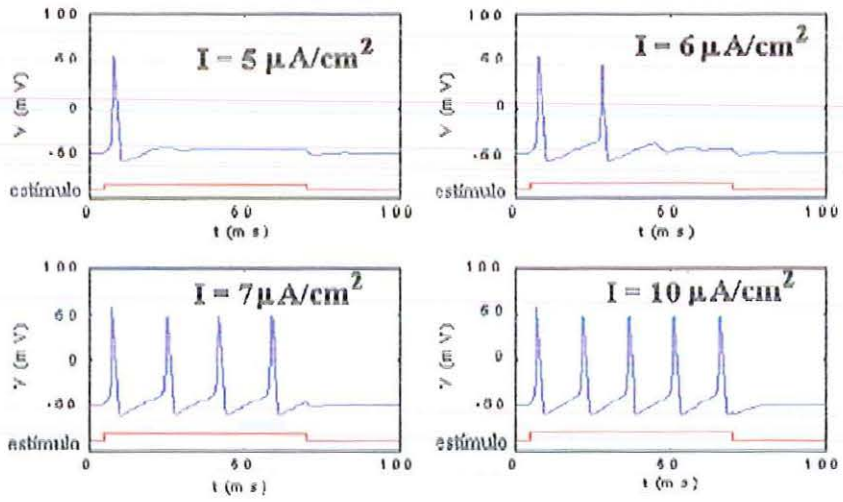

Figura 2.9 – Resposta de uma célula nervosa a diferentes estímulos de corrente

Vários estudos experimentais com células nervosas têm mostrado que, para cada valor de corrente injetada, haverá uma única freqüência de

disparos de potenciais de ação. Isto sugere que um neurônio atua como um conversor de corrente (ou voltagem, pela lei de Ohm) em freqüência. Ele codifica um estímulo por uma freqüência (Figura 2.9). O que condiz com o modelo clássico sobre a maneira como os neurônios codificam informação, ou seja, o que é importante para a sinalização de um evento por um neurônio não é o instante exato em que ele emite um potencial de ação, mas a freqüência de potenciais de ação emitidos por ele durante uma certa unidade de tempo.

2.4 Processo contrátil num músculo esquelético

Cerca de 90% do nosso corpo são formados por músculos esqueléticos sendo que os outros 10% são formados por músculos lisos e cardíacos. Apesar das diferenças histológicas, seus mecanismos de contração são semelhantes, neste enfoque iremos nos referenciar aos esqueléticos.

Um típico músculo esquelético é formado por numerosos conjuntos de fibras contráteis denominados **fascículos**. Cada fascículo é constituído, por sua vez, por numerosas **fibras**. A fibra apresenta uma resistente membrana que separa o seu meio interno do externo, denominada **sarcolema**. No interior da fibra se encontra um líquido intracelular denominado **sarcoplasma**. Submersos no sarcoplasma encontram-se numerosas unidades menores denominadas **miofibrilas**. No interior das miofibrilas encontram-se milhares de delgados filamentos protéicos: **Actina** e **Miosina** (Figura 2.10).

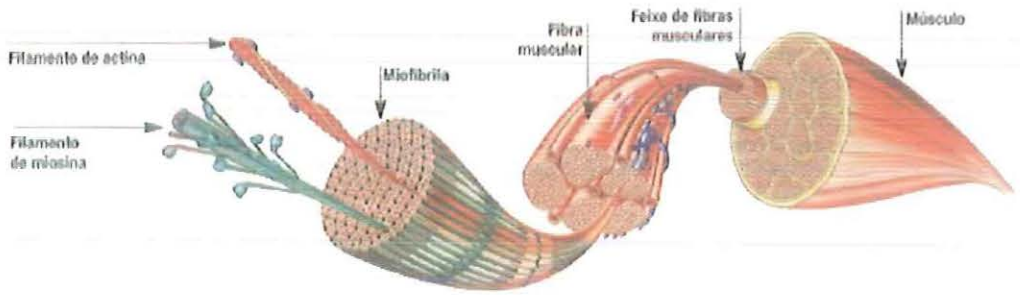

Figura 2.10 – Constituição de um músculo esquelético típico.

Vejamos, de que forma ocorre o processo contrátil num músculo esquelético:

Os filamentos de Actina e Miosina estão dispostos entre si de modo organizado, de tal forma que, durante o estado de excitação da fibra, deslizam-se uns sobre os outros. Tal deslizamento força um encurtamento das miofibrilas que estão no interior de uma fibra o que, conseqüentemente, faz com que a fibra inteira acabe também se encurtando.

Quanto maior é o número de fibras que se contraem simultaneamente durante um trabalho muscular, maior será a força de contração do mesmo.

Mas, afinal de contas, o que provoca tal deslizamento de filamentos protéicos?

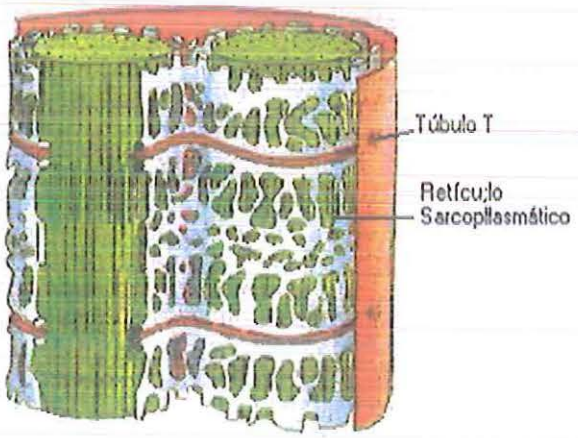

Figura 2.11 – O potencial de ação (PA) ganha as fibras musculares e é interiorizado para as miofibrilas através dos túbulos T. No Retículo Sarcoplasmático os PAs promovem aumento da permeabilidade da membrana à saída de Ca++ armazenado para o sarcoplasma, (adaptado de Guyton & Hall: Medical Physiology).

Um elemento que se encontra no interior das fibras musculares e que desempenha um papel muito importante no processo contrátil, o íon

cálcio. Uma grande quantidade de íons cálcio se armazena no interior de enormes e numerosos **retículos sarcoplasmáticos**, que se encontram distribuídos no interior das fibras. A permeabilidade ao cálcio na membrana de tais retículos é normalmente pequena e, além disso, existem potentes bombas de cálcio que, ativamente, transportam os tais íons do exterior para o interior dos retículos. Por isso encontramos uma grande concentração de íons cálcio no interior dos retículos sarcoplasmáticos (Figura 2.11).

Mas acontece que, ao receber um estímulo em sua placa motora, a fibra muscular se excita e, durante todo o tempo em que a mesma permanece excitada, um grande aumento na permeabilidade aos íons cálcio se verifica na membrana dos retículos sarcoplasmáticos que se encontram em seu interior. Devido ao aumento na permeabilidade aos íons cálcio, um grande fluxo destes íons se verifica do interior para o exterior do retículo sarcoplasmático. Os íons cálcio, então, liberados em grande número para fora dos retículos sarcoplasmáticos, ligam-se quimicamente nas diversas moléculas de **troponina**, presentes nos delgados filamentos de **actina** (Figura 2.12).

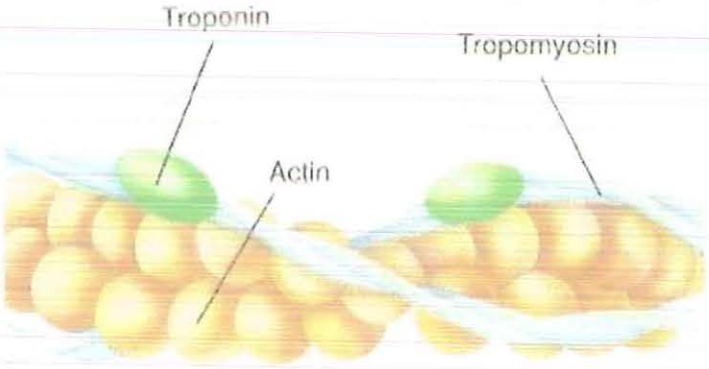

Figura 2.12 – A alta concentração de Ca++ no sarcoplasma ativa a Troponina-C (TN-C), alterando a configuração estrutural, (Guyton & Hall: Medical Physiology).

Isso provoca o deslizamento dos filamentos de actina sobre os de miosina, tracionados pelas *pontes cruzadas* destes últimos, que se engatam

quimicamente em determinados pontos (*pontos ativos*) dos filamentos de actina e os tracionam mecanicamente, como num mecanismo de roda denteada na corrente de uma bicicleta ou numa catraca ou mesmo numa cremalheira (Figura 2.13).

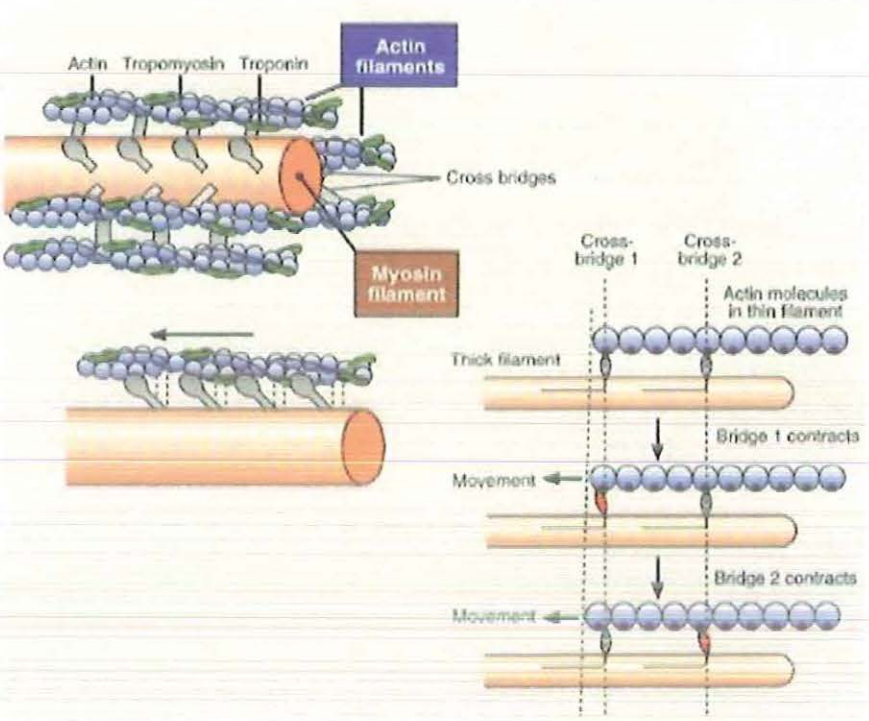

Figura 2.13 – A alteração da configuração estrutural desloca tropomiosina para sulco dos filamentos actina. Ocorre a exposição dos sítios de fixação para meromiosina pesada e uma molécula de ATP, formando as PONTES CRUZADAS. O ATP promove uma flexão do filamento de miosina (dobradiça) e o deslizamento entre os filamentos, (Guyton & Hall: Medical Physiology).

O processo descrito acima perdura enquanto a fibra muscular se mantém excitada. A mesma se mantém excitada enquanto continua recebendo estímulos químicos através de sua placa motora. A estimulação química na placa motora se faz através da liberação de acetil-colina pela terminação nervosa motora, enquanto os potenciais de ação ocorrem e se propagam à terminação nervosa. Uma vez cessada a excitação da fibra nervosa motora, os potenciais de ação através da mesma também cessam e, conseqüentemente, a excitação da fibra muscular também cessa. Imediatamente a permeabilidade

aos íons cálcio na membrana dos diversos retículos sarcoplasmáticos se reduz, retornando ao normal. Rapidamente, então, a quantidade de íons cálcio no exterior dos retículos sarcoplasmáticos também diminui bastante e, conseqüentemente, a força contrátil se desfaz, devido ao desligamento dos íons cálcio que se encontravam nos filamentos de actina. A fibra muscular, então, se relaxa.

2.5 Fatores que determinam a força de contração de um músculo esquelético durante seu trabalho

Quanto maior é o número de fibras musculares utilizadas ao mesmo tempo, num mesmo músculo, durante uma contração do mesmo, maior será a sua força contrátil.

Num típico músculo esquelético, formado com até milhares de fibras, muitas vezes um grande número de fibras são utilizadas simultaneamente durante um trabalho de contração.

Embora cada fibra seja individual, isto é, uma vez excitada se contrai, mas não passa a excitação para outra fibra qualquer, mesmo que essa outra fibra se encontre muito próxima, normalmente, um grande número de fibras num mesmo músculo são excitadas simultaneamente.

Existem numerosas fibras que são inervadas, embora individualmente, por terminações de ramificações axônicas de uma mesma célula nervosa motora. Um conjunto de fibras musculares inervadas por ramificações de uma mesma célula nervosa motora forma aquilo que chamamos de **Unidade Motora**. Existem numerosas unidades motoras num mesmo músculo, de diversas densidades. As maiores, formadas por um grande número de fibras musculares (centenas), geralmente são inervadas por células nervosas motoras mais calibrosas, de baixa excitabilidade. São, portanto, mais

dificilmente excitáveis e necessitam de grandes estímulos para que possam se contrair. Já as unidades motoras menores, formadas por um baixo número de fibras musculares (algumas dezenas) são, geralmente, inervadas por células nervosas motoras menos calibrosas e mais excitáveis. São, portanto, muito mais facilmente excitáveis e não exigindo grande intensidade de estímulos para que suas contrações ocorram.

De acordo com as afirmações descritas acima, pode-se concluir que, na medida em que se aumentam a intensidade dos estímulos numa determinada área motora do sistema nervoso central responsável pela contração de um determinado músculo esquelético, mais intensas seriam suas contrações, pois um número cada vez maior de unidades motoras naquele músculo seriam utilizados. A isto chamamos **Somação de Unidades Motoras**.

Outro fator importante que interfere na força de contração de um determinado músculo esquelético, é a freqüência dos potenciais de ação que se dirigem às terminações axônicas que se ligam às suas placas motoras. Quanto maior a freqüência de tais impulsos nervosos, maior será a quantidade de mediadores químicos (acetil-colina) liberados na placa motora muscular e, com isso, maior será a estimulação da mesma. Além disso, as repetidas e rápidas contrações musculares se somam umas às outras e, numa freqüência alta, vão aumentando o estado contrátil das fibras musculares. Portanto, na medida em que aumentamos a freqüência dos estímulos em um conjunto de fibras nervosas motoras que se dirigem a um músculo esquelético, mais intensas serão as contrações do mesmo devido ao que chamamos de **Somação de Ondas**.

CAPÍTULO 3

COMPENSAÇÃO DO EFEITO DOS TECIDOS SUBCUTÂNEOS NA EMG DE SUPERFÍCIE

3.1 Introdução

A possibilidade de compensar os efeitos dos tecidos subcutâneos, quando suas propriedades podem ser estimadas, permite obter melhor estimação dos parâmetros de amplitude e freqüência, bem como simplificar o complexo problema da decomposição do sinal EMGS em seus MUAPs constituintes.

Conforme foi explicado no tópico 2.3, o potencial de ação da unidade motora (MUAP), é gerado pelas zonas despolarizadas das fibras musculares ativas, o qual através de músculos e tecidos subcutâneos, alcança a pele onde é detectado (Figura 3.1-(c)). O tecido através do qual o sinal se propaga é chamado de volume condutor. O efeito do volume condutor sobre os sinais detectados na superfície da pele é responsável pelas vantagens e limitações das técnicas de EMG de superfície com respeito a técnicas invasivas (neste último caso o efeito do volume condutor é desprezível). Os tecidos biológicos determinam um espalhamento no potencial, tal que os sinais detectados contém contribuições de diversas fontes diferentes e coletam informação global sobre a atividade muscular. Esta característica oferece muitas vantagens em quaisquer aplicações onde informação localizada não é de interesse, mas por outro lado, determina dificuldades na separação de

diferentes contribuições e na detecção de sinais não afetados por outros músculos ativos (fenômenos de superposição).

O sinal da EMGS convencional é a superposição de um grande número de UMs, que estão localizadas dentro do músculo em vários arranjos geométricos, e são ativadas em um complexo padrão de interferência. Existe grande dificuldade para separação da atividade individual de uma UM das outras UMs adjacentes, que estão simultaneamente ativas. O arranjo do sistema de condutores na EMGS convencional usualmente consiste de grandes eletrodos (diâmetro acima de 10 mm) em um arranjo bipolar (distância intereletródica mínima de 10 mm), (Basmajian & De Luca, 1985). Devido a baixa resolução espacial desse sistema, a EMGS convencional reflete apenas a atividade composta de um grande número de UMs. Entretanto, a EMGS convencional é usada para obtenção de informação sobre o tempo e a intensidade da ativação de músculos superficiais com aplicações bem fundamentadas em biomecânica, biofeedback, e reabilitação, não sendo, contudo adequada para a detecção da atividade individual da UM.

Técnicas de aquisição invasivas, como eletrodos de agulha ou de fio, tem uma alta resolução espacial. Em contraste com a EMGS convencional, elas permitem a detecção da atividade individual da UM, no entanto a inserção da agulha ou do fio causa desconforto, requer supervisão médica e pode trazer risco de infecção. Além disto, a repetibilidade das medidas é pobre, e um monitoramento em longo prazo é praticamente inviável, (Jonsson & Bragge, 1968). A EMGS convencional usualmente não provê informação a respeito da difusão da excitação. A EMG de fio supera alguns problemas da EMG de agulha, como o desconforto/dor e incrementa a informação sobre a difusão da excitação. Este método é difícil de usar na prática, porque após a inserção, os eletrodos de fio tendem a migrar no interior do tecido muscular durante a contração. Por esta razão, a reprodutibilidade do sinal EMG detectado com

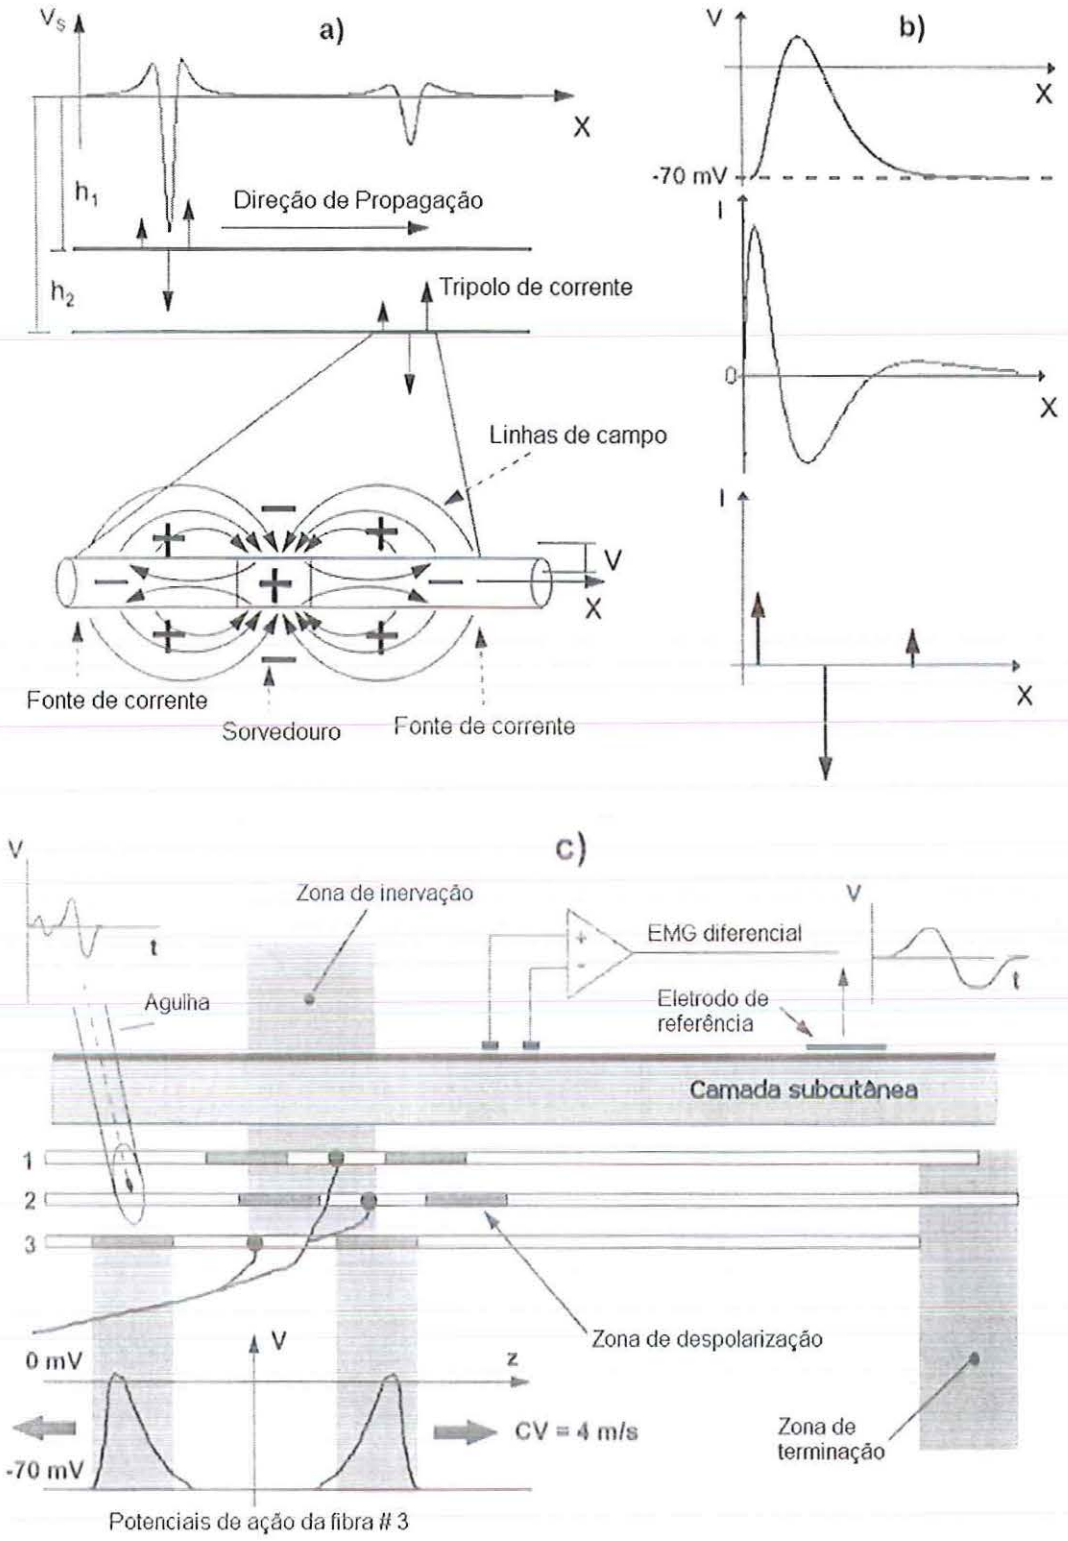

Figura 3.1 – (a) Zona de despolarização da fibra muscular, descrição da corrente de membrana, e do potencial de superfície monopolar V_S gerado sobre a pele por duas zonas despolarizadas em duas profundidades h_1 e h_2; (b) Voltagem transmembrana da fibra muscular, corrente e modelo tripolo da corrente transmembrana; (c) Representação esquemática de uma unidade motora (três fibras somente) e do sinal detectado pelo amplificador diferencial (eletrodos de superfície) e por um de agulha coaxial. (Adaptado de Farina & Rainoldi, 1999).

eletrodos de fio se aplicam mais a parâmetros totais do sinal EMG (como amplitude) do que a parâmetros individuais das UMs. A maior vantagem dos eletrodos de fio é a possibilidade de captar a atividade muscular dos músculos mais profundos, mesmo durante a contração dinâmica.

A distribuição de potencial gerada na superfície da pele pela atividade muscular (voluntária ou induzida eletricamente), contém informação sobre a atividade individual da UM. Conseqüentemente, a atividade individual da UM torna-se detectável não invasivamente quando a resolução espacial do sistema de aquisição é aumentada. Um primeiro passo nessa direção foi o desenvolvimento de eletrodos ativos, que permitem a detecção de sinais de amplitude muito baixa, (Basmajian & De Luca, 1985) e (Merletti & De Luca, 1989). Esta técnica tornou possível reduzir a distância intereletródica, e desse modo aumentar a resolução espacial do sistema de aquisição, (Lynn et al., 1978). Uma outra abordagem é baseada sistemas de eletrodos bipolares concêntricos (Van S.R., 1986), que consiste de um eletrodo central rodeado por um anel concêntrico. O sistema concêntrico, bem como o bipolar, com distância intereletródica na faixa de alguns milímetros, permitem a detecção não invasiva da atividade individual da UM, mas os procedimentos são limitados à 20% da contração voluntária máxima do músculo. Além desse nível de força, muitas UMs são ativadas, formando um padrão de interferência bem conhecido, ao passo que a decomposição do sinal no tempo para isolar um MUAP é muito difícil.

A detecção não invasiva da atividade de UMs isoladas, mesmo durante a contração voluntária máxima do músculo, se tornou possível pela primeira vez quando arranjos de eletrodos foram usados em combinação com o processo de filtragem espacial, (Reucher et al., 1987). Esta abordagem foi de fato uma extensão dos sistemas especializados bipolares ou tripolares usados por Masuda & Sadoyama, 1986.

Recentemente, novas técnicas de detecção do sinal EMG superficial têm sido introduzidas, elas são baseadas em matrizes de eletrodos que permitem melhorar consideravelmente a seletividade espacial, sendo denominada eletromiografia de alta resolução espacial (EMG-ARE).

Vários estudos prévios enfocaram a influência dos parâmetros anatômicos, físicos, e do sistema de detecção em sinais EMG de superfície. Muitos deles foram conduzidos por simulações, mais recentemente um modelo de geração e propagação do sinal EMG de superfície levando em conta o efeito dos tecidos subcutâneos foi proposto por Farina et al. (2002), o modelo caracteriza o volume condutor como um meio não-homogêneo e anisotrópico. A influência da espessura das camadas dos tecidos subcutâneos, a inclinação da fibra, a profundidade da fibra, o tamanho e a forma dos eletrodos, a função de transferência do filtro espacial, a distância intereletródica, o comprimento das fibras, a amplitude do potencial de ação de fibra única, o conteúdo de freqüência e a velocidade de condução estimada foram investigados por eles, implicações dos resultados nos procedimentos de posicionamento dos eletrodos, projeto de filtros espaciais, e interpretação do sinal EMG foram discutidos. Os resultados deste estudo são particularmente interessantes, pois além de mostrar que os tecidos subcutâneos produzem uma atenuação e alargamento da distribuição de potencial presente na superfície da pele acima do músculo, mostra que é possível a compensação destes efeitos, permitindo atenuar o problema da superposição e detectar os MUAPs com menor grau de superposição. A partir do modelo desenvolvido a função de transferência teórica das camadas de gordura e pele pôde ser calculada e um sistema de detecção para compensar esses efeitos foi projetado. Este sistema de detecção é baseado em uma matriz de eletrodos com pesos particulares associados, o qual atua como um filtro inverso, podendo ser visto como se fosse uma lente focalizadora.

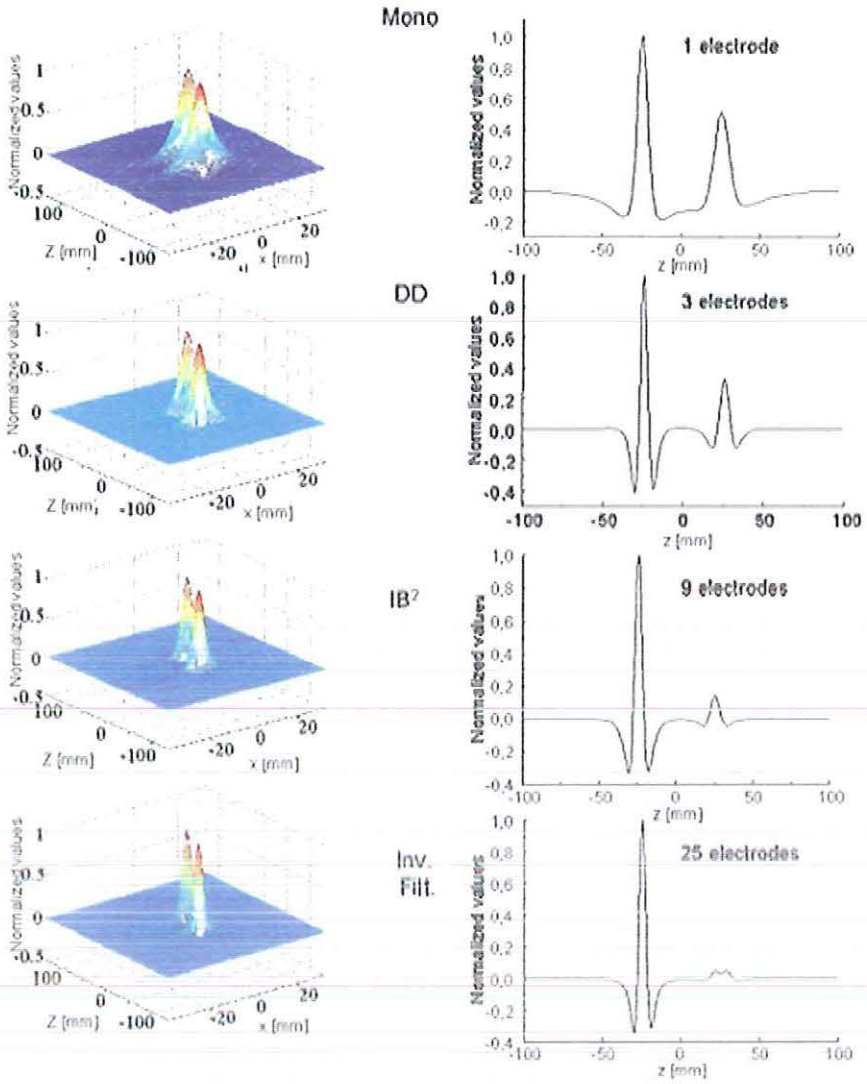

Figura 3.2 – Distribuição de potencial e secção ao longo do eixo z gerada por dois tripolos a uma profundidade de 2 mm e a uma distancia de 5 mm ao longo do eixo x e 50 mm ao longo do eixo z, obtido com diferentes sistemas de detecção: monopolar, duplo diferencial, filtro binomial inverso de segunda ordem e filtro inverso aproximado. Os gráficos da coluna à direita mostram o sinal de saída detectado pelo sistema de detecção posicionado em x=0, (de Farina et al., 2002).

Resultados da aplicação dos filtros propostos são apresentados na Figura 3.2, que mostra sinais detectados com diferentes sistemas de detecção e gerados por duas fibras musculares a uma distância de 5 mm. É evidente que a detecção monopolar não permite distinguir entre duas fontes, enquanto que os sistemas mais complexos são mais seletivos. Em particular podemos ver os

resultados da aplicação do filtro duplo diferencial, um sistema de detecção comum na EMG de superfície, que é um filtro passa-altos projetado sem o conhecimento das propriedades dos tecidos subcutâneos, e os filtros inversos de 9 e 25 eletrodos, os quais são projetados para compensar os efeitos do volume condutor. Os filtros até então propostos pela literatura são de uso geral, e não são baseados nas propriedades fisiológicas das camadas de tecidos do volume condutor. O projeto de filtros com melhores características em termos de seletividade espacial, e boa isotropia, propriedade que faz com que a detecção não seja afetada pela direção das fibras com relação ao eletrodo, leva em conta as propriedades do volume condutor, como é o caso dos dois tipos de filtros inversos da Figura 3.2, que apresentam elevada seletividade espacial além de uma boa isotropia.

3.2 Eletromiografia de superfície de alta resolução espacial

Uma distribuição de potencial variando com o tempo é gerada na superfície da pele pela excitação das fibras musculares. Quando se usa um arranjo bidimensional de eletrodos, os potenciais captados pelos diferentes eletrodos ao mesmo tempo, podem ser considerados como amostras espaciais de uma distribuição de potencial. Um modelo teórico (Teoria do Volume-Condutor, Rosenfalck, 1964) considerando a anatomia muscular bem como a difusão da excitação baseia-se em um tripolo elétrico movendo-se com uma velocidade de condução ao longo do eixo longitudinal das fibras musculares (Figura 3.1), (Griep et al., 1982), (Phonsey, 1984), (Reucher et al., 1987), (Farina & Rainoldi, 1999), e (Farina et al., 2002). A partir desse modelo pode-se calcular a distância intereletródica máxima necessária para se obter a informação completa sobre a distribuição de potencial na superfície da pele. Foi mostrado que para músculos superficiais, tais como, por exemplo, o bíceps braquial ou o abdutor pollicis brevis, esta meta pode ser alcançada apenas

quando são usadas distâncias intereletródicas na faixa milimétrica (5 mm para o bíceps, 2.5 mm para o pollicis brevis), (Reucher et al., 1987). A distância intereletródica deve ser adaptada para as dimensões do músculo e do volume condutor, respectivamente, os quais influenciam as propriedades do campo elétrico na superfície da pele.

O principio da filtragem espacial é baseado no fato das UMs situadas próximas à superfície da pele contribuírem para a distribuição de potencial na superfície da pele com um gradiente de potencial espacialmente íngreme. Em contraste, a atividade das UMs mais distantes, como fontes de distúrbios elétricos mais afastados, geram um curso de potencial espacialmente mais plano (Figura 3.3). Um condutor bipolar com uma distância intereletródica na faixa milimétrica, que forma em princípio um filtro espacial de baixa ordem, diferencia a distribuição de potencial na direção da configuração do eletrodo. Deste modo, a inclinação da distribuição de potencial gerada por UMs localizadas próximas da superfície da pele contribuem mais para o sinal diferença resultante do que a baixa inclinação da distribuição de potencial originada pelas UMs mais distantes (Figura 3.3). O condutor bipolar com distância intereletródica na faixa milimétrica amplifica a atividade das UMs localizadas próxima da superfície da pele e reduz a atividade das fontes mais afastadas.

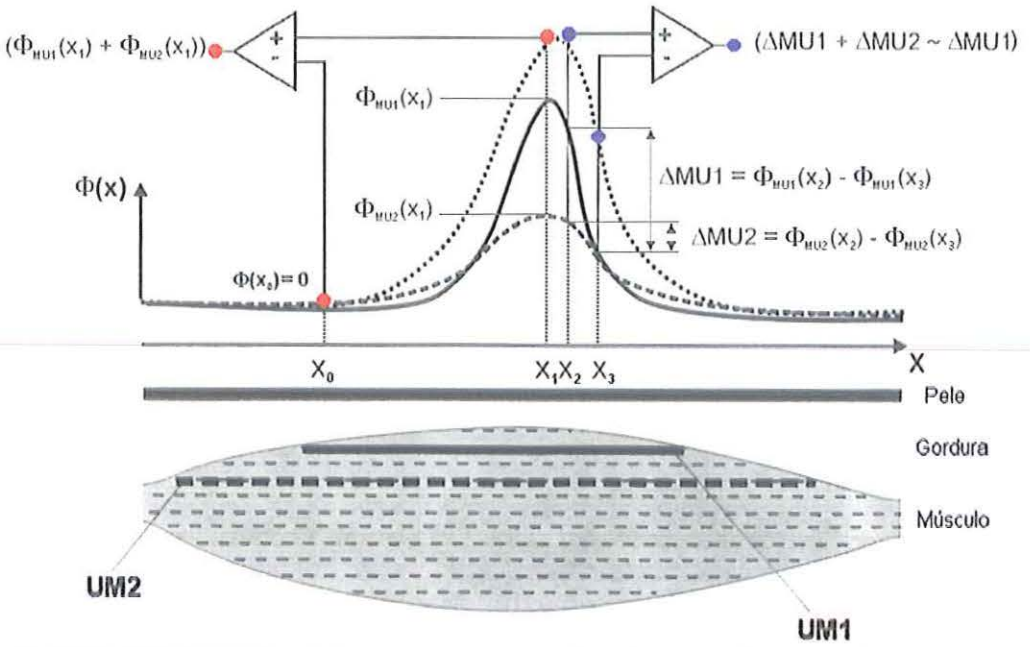

Figura 3.3 – Diagrama da distribuição de potencial Φ(x) gerado na superfície da pele por duas unidades motoras distintas (UM1 e UM2) num dado momento. É assumido que UM1 está mais próxima da superfície da pele e UM2 mais distante.Devido a maior proximidade da superfície UM1 produz uma distribuição de potencial espacialmente íngreme. Em contraste, UM2 produz uma distribuição espacialmente plana. Usando condutores bipolares com uma grande distância intereletródica ambas UMs contribuem significativamente para o sinal diferença resultante (lado esquerdo). No caso de pequenas distâncias intereletródicas, a UM1 contribui com a maior parte do sinal medido (lado direito). Este princípio é conhecido como filtragem espacial high-pass da distribuição de potencial. (Adaptado de Disselhorst-klug et al., 2000).

Devido à filtragem espacial os condutores bipolares permitem a detecção da atividade isolada de UMs em baixos níveis de contração do músculo, quando poucas UMs estão ativas (Merletti & De Luca, 1989), (Reucher et al., 1987). Contudo, a resolução espacial dos condutores bipolares não é suficiente para discriminar a atividade individual das UMs sob altos níveis de força de contração. Em conseqüência, essa primeira abordagem foi estendida para três ou mais condutores unipolares (Reucher et al., 1987). A somatória ponderada de três condutores unipolares em linha realiza uma dupla diferenciação da distribuição espacial. Devido a dupla diferenciação, este filtro separa a atividade individual de UMs próximas a superfície da pele daquelas localizadas mais distantes da pele (Figura 3.4). A seletividade espacial do

filtro duplo diferencial é alta na direção da linha formada pelos eletrodos, entretanto, mesmo assim fontes laterais distantes podem contribuir para o curso do sinal (Figura 3.4).

Esta desvantagem pode ser evitada usando-se um arranjo com cinco eletrodos. Este arranjo como um filtro espacial é chamado filtro normal duplo diferencial (filtro NDD) (Reucher et al., 1987). Os cincos condutores do filtro NDD são dispostos em cruz (Figura 3.4). Para construir um filtro espacial cada eletrodo do filtro deve ser ponderado por um fator determinado pela equação de Laplace (o eletrodo central é ponderado por um fator de - 4 e sua vizinhança com fator + 1). Este filtro melhora a seletividade espacial em todas as direções, e desse modo permite a separação não invasiva das atividades individuais das UMs mesmo sob contração voluntária máxima (Figura 3.4), como foi mostrado por Reucher e colaboradores, (1987).

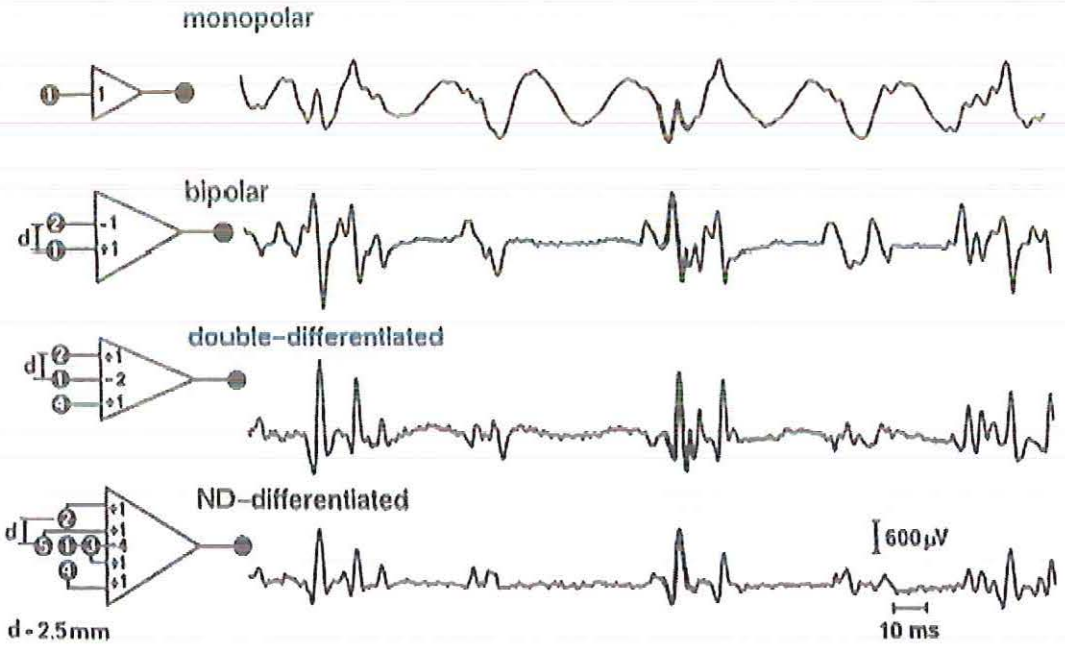

Figura 3.4 – Representação de quatro diferentes configurações de eletrodos usados na aquisição do sinal mioelétrico do músculo abdutor pollicis brevis sob contração voluntária máxima. Uma excitação de uma UM foi enfatizada. (de Rau & Disslhorst-Klug, 1997).

Para a realização de filtros espaciais, são requeridos eletrodos de pequenas dimensões, a eletromiografia de alta resolução espacial (EMG-ARE) em geral usa eletrodos de pinos com pequena superfície (diâmetro de 0.5 mm e distância intereletródica de 2.5 – 5 mm), dispostos em configuração matricial. Isto resulta em uma impedância extremamente alta entre a superfície da pele e os eletrodos. Para obter uma relação sinal-ruído aceitável, os eletrodos devem ser conectados diretamente a um pré-amplificador com alta escala de integração e capacitância de entrada extremamente baixa.

3.3 Aplicação em diagnóstico de desordens neuromusculares

O principal objetivo da EMG de agulha no diagnóstico de desordens neuromusculares é distinguir entre pacientes sem qualquer tipo de desordem neuromuscular daqueles com desordens musculares e com desordens neuronais. Desordens neuromusculares estão freqüentemente relacionadas com mudanças típicas na estrutura das UMs. Conseqüentemente, o diagnóstico destas desordens está essencialmente baseado na informação sobre a atividade elétrica das UMs individuais. A EMG-ARE fornece esta informação e é, em conseqüência, uma ferramenta não invasiva adequada para o diagnóstico de desordens neuromusculares, podendo substituir com vantagens a EMG de agulha.

Um estudo clínico foi feito mostrando a habilidade da EMG-ARE para distinguir entre pacientes destes três grupos (Rau & Disselhorst-Klug, 1997), neste estudo foram usados eletrodos na configuração de filtro NDD. A EMG-ARE foi gravada durante a CVM do músculo abdutor pollicis brevis em 117 voluntários (61 crianças sadias, 35 pacientes com distrofia muscular Duchenne e 21 pacientes com atrofia músculo espinal). Os seus resultados mostram que a EMG-ARE permite a detecção das mudanças típicas na atividade elétrica das UMs nas desordens neuronais e musculares (Figura 3.5).

Contudo, devido a filtragem espacial o método é limitado a UMs superficiais em músculos superficiais. A despeito dessas limitações, a EMG-ARE detecta mudanças na atividade elétrica de UMs que são típicas em desordens musculares e neuronais.

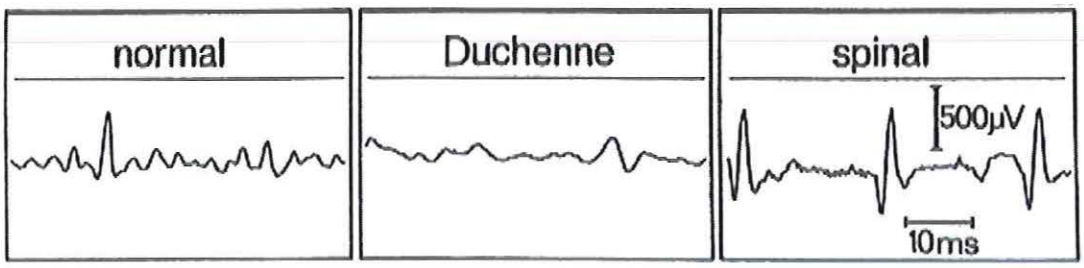

Figura 3.5 – Sinal EMG-ARE de crianças com diferentes tipos de desordens neuromusculares. (de Rau & Disselhorst-Klug, 1997).

CAPÍTULO 4

DECOMPOSICÃO DE SINAIS MIOELÉTRICOS

4.1 Introdução

Este capítulo tem objetivo de apresentar os aspectos básicos relativos à composição de sinais mioelétricos e métodos para decomposição dos mesmos, importantes para a compreensão das técnicas propostas no trabalho.

Os vários passos envolvidos na decomposição do sinal EMG serão descritos e aspectos importantes relativos a cada um desses passos serão discutidos. Serão apresentados ainda alguns usos para os resultados da decomposição, em diagnóstico e gerência de desordens neuromusculares e na pesquisa avançada da fisiologia neuromuscular, visando aprimorar o entendimento dos efeitos de doenças, envelhecimento e fadiga.

4.2 Composição do sinal eletromiográfico

Antes de apreciar os conceitos envolvidos com a decomposição do sinal EMG é essencial nos familiarizarmos com a composição do sinal EMG. É interessante então considerarmos um modelo matemático simples para o sinal EMG de forma que influencias anatômicas, fisiológicas e fatores elétricos possam ser entendidos, (Figura 4.2, Basmajian & De Luca, 1985).

4.2.1 Potencial de ação da fibra muscular (MFAP)

O **potencial de ação da fibra muscular** (MFAP), que é a componente fundamental contribuindo para o sinal EMG detectado, resulta da propagação de um **potencial de ação** (PA) ao longo da membrana excitável de uma fibra muscular. A forma de onda resultante da detecção do PA viajando ao longo da iésima fibra de uma **unidade motora** (UM) é denominada $MFAP_i(t)$. As características do $MFAP_i(t)$ dependem do diâmetro da fibra, da velocidade com que ela conduz o PA, da sua localização relativa ao eletrodo de detecção, e da configuração do sistema de detecção. Fibras de grandes diâmetros geram grandes MFAPs. PAs conduzidos mais lentamente geram MFAPs que tem longa duração. A magnitude e o conteúdo de alta freqüência de um MFAP decresce com a distância entre o eletrodo e a fibra ou com o aumento da área superficial do eletrodo.

4.2.2 Potencial de ação da unidade motora (MUAP)

As fibras de um músculo não são excitadas individualmente. Elas são controladas em grupos, chamadas unidades motoras. Formalmente, uma unidade motora é um motoneurônio alfa, seus axônios e todas as fibras musculares inervadas por ele. Sob circunstancias normais os MFAPs individuais não são detectados, ao invés a somatória de todos os MFAPs de uma unidade motora ou um **potencial de ação da unidade motora** (MUAP), *h(t) na* Figura 4.1, é detectado. Seja o $MUAP_j(t)$ o potencial detectado quando a j-ésima unidade motora dispara:

$$MUAP_j(t) = \sum_{i=1}^{N_j} MFAP_i(t - \tau_i) \cdot s_i \qquad \textbf{(4.1)}$$

onde τ_i é o offset temporal do $MFAP_i(t)$; N_j é o número de fibras na unidade motora j; s_i é uma variável binária usada para representar a função da junção neuromuscular que tem valor 1 se a fibra i dispara e 0 se a fibra é bloqueada (i.e. não dispara).

τ_i, o offset temporal da i-ésima fibra, é dependente da locação da junção neuromuscular e da sua velocidade de condução. N_j representa o tamanho da unidade motora. O número de fibras dentro de uma unidade motora pode teoricamente determinar o tamanho do MUAP. Contudo, devido à atenuação do tamanho do MFAP com a distância ao eletrodo de detecção, o tamanho do MUAP na pratica é dependente da locação e diâmetro de umas poucas fibras mais próximas do sitio de detecção. Então, o número de fibras próximas do eletrodo detector e seus diâmetros determinam, em sua maior parte, a forma de um MUAP, como mostra a Figura 4.1.

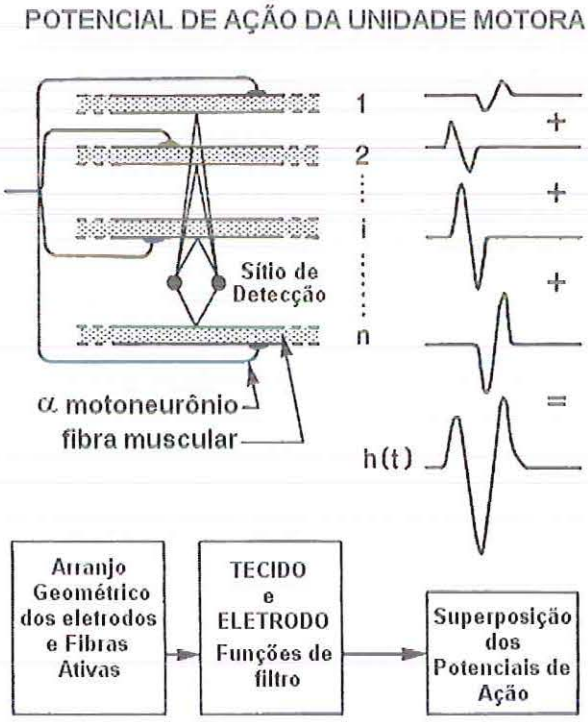

Figura 4.1 - Um MUAP é composto do somatório dos potenciais de ação das fibras musculares (MFAP) componentes da UM. A localização da fibra muscular relativa ao eletrodo, a área superficial, a configuração do eletrodo e o diâmetro da fibra afetam grandemente esta contribuição. MUAPs para uma UM em particular variam devido a variações aleatórias no inicio dos MFAPs e a diferentes velocidades de condução do MFAP (Adaptado de Basmajian & De Luca, 1985).

O atraso na condução (τ_i) para cada fibra da unidade motora flutua, disparo a disparo, devido principalmente à variação no tempo requerido pela junção neuromuscular da fibra para despolarizar sua membrana pós-sináptica e iniciar a propagação do MFAP. Isto por seu turno causa variações biológicas na forma dos MUAPs de uma unidade motora através de suas descargas ao longo do tempo. Em geral, as formas de onda dos MUAPs variam devido a variações no atraso do potencial de fibra (afetando τ_i), possíveis mudanças na posição do eletrodo relativa as fibras musculares (afetando $MFAP_i$), e a possibilidade de uma fibra particular falhar o disparo (afetando s_i). Estas variações são a fonte da variabilidade biológica estocástica na forma de onda do MUAP.

4.2.3 Trem de potenciais de ação da unidade motora (MUAPT)

Unidades motoras devem disparar repetidamente para manter ou aumentar a força gerada por um músculo. Deste modo, durante uma contração sustentada cada unidade motora gera múltiplos MUAPs. A coleção de MUAPs gerados por uma unidade motora, posicionados em seus tempos de ocorrência ou separados por seus **intervalos interpulsos** (IPIs) é chamado **trem de potenciais de ação da unidade motora** (MUAPT).

Definimos a forma do MUAP presente no sítio de detecção como ***h(t)*** e o tempo no qual ocorre o disparo como δ_k, então o MUAPT pode ser expresso como:

$$MUAPT_j(t) = \sum_{k=1}^{M_p} h_{jk}.(t - \delta_{jk}) \qquad (4.2)$$

onde $MUAPT_j(t)$ é o MUAPT da j-ésima unidade motora; $h_{jk}(t)$ é o MUAP gerado durante o k-ésimo disparo da j-ésima unidade motora; M_p é o número

de vezes que a j-ésima unidade motora dispara; δ_{jk} é o k-ésimo tempo de disparo da j-ésima unidade motora.

Devido a variações biológicas na forma do MUAP de uma unidade motora, cada $MUAP_{jk}(t)$ é único. Conforme o nível de contração aumenta, o número de unidades motoras ativas (i.e. o número de MUAPTs) bem como o número de MUAPs por segundo em cada trem aumenta. Além disso, grandes unidades motoras, que produzem grandes MUAPs, se tornam ativas à medida que o nível de força é aumentado, (Basmajian & De Luca, 1985).

4.2.4 Sinal EMG composto

Um eletrodo medindo um campo de potencial elétrico em um meio, forma um volume condutor. Devido à propriedade de superposição dos campos elétricos, o eletrodo irá medir uma malha de potencial elétrico, que é uma soma espacial e temporal das contribuições de potencial de todas as fibras musculares excitadas (de qualquer UM). Então, o sinal EMG composto é simplesmente a somatória dos MUAPTs de todas UMs recrutadas, Figura 4.2.

Então o sinal EMG alcançando um eletrodo pode ser expresso como:

$$m(t,F) = \sum_{j=1}^{N_m} MUAPT_j(t,F) = \sum_{j=1}^{N_m} \sum_{k=1}^{M_p} h_{jk}(t - \delta_{jk}) \qquad (4.3)$$

onde F representa o nível da força de contração e é monotônicamente relacionado a M_p, o número de MUAPs detectados pelo eletrodo, sendo N_m o número de UMs ativas.

O eletrodo possui características próprias, que influenciam o sinal EMG que de fato está sendo detectado. Assim a expressão completa para o sinal EMG bruto é:

$$m(t,F) = r(t,d) \cdot \sum_{j=1}^{N_m} \sum_{k=1}^{M_p} h_{jk}(t - \delta_{jk}) + n(t) \qquad \textbf{(4.4)}$$

Onde ***r(t)*** representa o efeito de filtragem do eletrodo, ***d*** é o espaçamento entre as superfícies de detecção do arranjo diferencial usado em eletromiografia de superfície, e ***n(t)*** representa ruídos estranhos detectados pelo eletrodo.

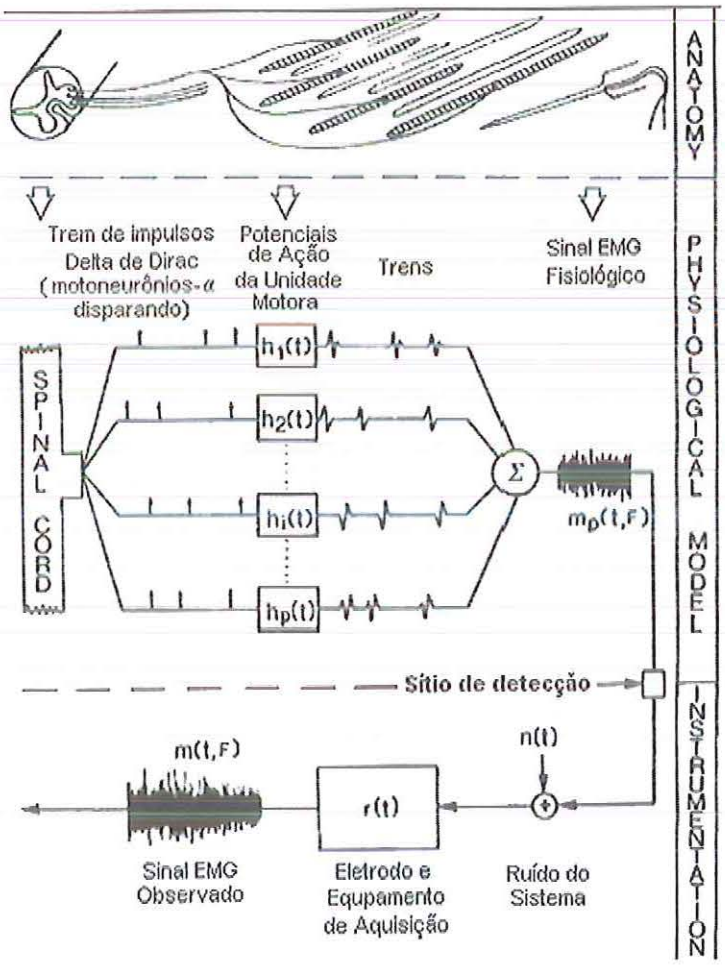

Figura 4.2 - Modelo fisiológico e matemático para a composição do sinal EMG detectado, (Adaptado de Basmajian e De Luca, 1985).

O espectro da densidade de potência de um MUAPT pode ser modelado pela seguinte equação, (Basmajian e De Luca, 1985):

$$S_{u_i}(\omega,t,F) = S_{\delta_i}(\omega,t,F)\left|H_i(j\omega)\right|^2 = \frac{\lambda_i(t,F).\left\{1-\left|M(j\omega,t,F)\right|^2\right\}}{1-2.\mathrm{Re}al\left\{M(j\omega,t,F)\right\}+\left|M(j\omega,t,F)\right|^2}\left\{\left|H_i(j\omega)\right|^2\right\} \quad \textbf{(4.5)}$$

$$p/\omega \neq 0$$

Onde;

S_{ui} = espectro da densidade de potência de um MUAPT individual;

ω = freqüência em radianos;

t = tempo em segundos;

$S_{\delta i}$ = trem de impulsos de delta de Dirac que representa os períodos de descarga do MUAPT;

F = nível da força de contração;

H_i = transformada de Fourier da forma de onda de um MUAP individual;

j = número imaginário;

λ_i = taxa de disparo média de uma UM individual;

M = transformada de Fourier da função probabilidade de distribuição do intervalo entre pulsos.

O espectro da densidade de potência do sinal EMG pode ser modelado pela seguinte equação:

$$S_m(\omega,t,F) = R(\omega,d)\left[\sum_{i=1}^{p(F)} S_{u_i}(\omega,t) + \sum_{i,j=1}^{q(F)} S_{u_i u_j}(\omega,t)\right] \quad \textbf{(4.6)}$$

Onde;

S_m = espectro da densidade de potência do sinal EMG;

ω = freqüência angular em radianos;

t = tempo em segundos;

F = nível da força de contração;

R = função filtro do eletrodo;

d = espaçamento entre as superfícies de detecção do eletrodo;

p = número total de MUAPTs que compõe o sinal;

S_{ui} = espectro da densidade de potência de um MUAP individual;

q = número de MUAPTs com descargas correlacionadas;

$S_{ui,uj}$ = espectro de potência cruzado da UM_i e UM_j.

Embora complexas, as equações 4 e 5 mostram que são afetadas principalmente pelo espectro de freqüência das UMs individuais, $H_i(j\omega)$. Estes espectros são alterados somente se a forma dos MUAPs $h_i(t)$ são alterados. Este fato é bem conhecido, dado que durante contração sustentada a duração de $h_i(t)$ aumenta, conseqüentemente, o espectro da densidade de potência do sinal EMG é alterado.

Teoricamente, um sinal EMG é composto das contribuições de todas as fibras ativas no músculo. Contudo, devido à separação radial entre fibras musculares distantes e a superfície de detecção do eletrodo, a amplitude e o conteúdo de alta freqüência das contribuições dos MFAPs de fibras distantes podem ser atenuados abaixo do nível do ruído de fundo. As contribuições para um sinal EMG que podem ser praticamente consideradas são dependentes da posição do eletrodo relativa as fibras musculares ativas e as características físicas do eletrodo. Por exemplo, um eletrodo com uma pequena superfície de detecção colocado bem próximo a uma fibra muscular deve detectar principalmente a atividade elétrica desta fibra, e assim a atividade de uma única UM. Alternativamente, para uma grande superfície de

detecção, haverá muitas fibras que estão igualmente próximas, produzindo muitas contribuições igualmente semelhantes e assim tornando impossível detectar seletivamente a atividade individual das fibras, e difícil distinguir a atividade individual das UMs.

Assim sendo, as formas dos MUAPs dentro dos MUAPTs, e o número de UMs que podem ser consideradas estarem produzindo MUAPTs com MUAPs significantes para um sinal detectado, dependem da configuração dos eletrodos de detecção e sua localização em relação às fibras musculares contribuintes. Assim, sinais detectados por eletrodos com pequena área superficial ou micro-eletrodos, são considerados compostos basicamente por conteúdo de freqüência relativamente alta e de poucas UMs com poucas fibras próximas ao eletrodo. Alternativamente, sinais detectados por eletrodos com grande área superficial ou macro-eletrodos, são considerados compostos principalmente por contribuições de baixa freqüência e de um grande número de UMs com muitas de suas fibras próximas ao eletrodo. Conseqüentemente, em sinais detectados com micro-eletrodos, ocorrências de MUAPs isolados e contribuições de fibras individuais para os MUAPs podem ser facilmente detectadas, sendo, portanto mais fácil decompor estes sinais. Por outro lado, em sinais detectados com macro-eletrodos, é mais difícil detectar ocorrências de MUAPs isoladas e impossível detectar as contribuições individuais das fibras para os MUAPs, sendo, portanto mais difícil à decomposição destes sinais.

4.3 Como pode um sinal EMG ser decomposto?

4.3.1 Suposições básicas

A decomposição do sinal EMG é o processo de resolução do sinal EMG composto em seus MUAPTs constituintes. Os dois pressupostos básicos que devem ser considerados sobre a habilidade para decompor um sinal EMG são que, todos os disparos (MUAPs) das UMs significantes contribuintes para o sinal composto podem ser detectados e que cada MUAP detectado pode ser corretamente associado com a UM que o gerou. Isto requer métodos para detecção dos MUAPs e reconhecimento dos MUAPs detectados. Para detectar os MUAPs algumas características da sua forma, comuns a todos MUAPs, devem ser usadas para identificar sua ocorrência dentro do sinal composto. O reconhecimento dos MUAPs detectados requer que os MUAPs produzidos por uma dada UM sejam mais similares na forma do que os MUAPs produzidos por outras UMs diferentes e que diferenças nas formas dos MUAPs possam ser determinadas. O reconhecimento dos MUAPs detectados requer ainda que os MUAPs de cada UM ocorram varias vezes (mas não ao mesmo que os MUAPs de outras UMs), tal que as respectivas formas do MUAPs para cada UM ativa possam ser determinadas. Considerações e restrições que governam o projeto e uso de um sistema de decomposição e as varias tarefas envolvidas na execução da decomposição de um sinal EMG incluindo segmentação, agrupamento, classificação supervisionada, resolução de superposição, e a descoberta de relações temporais entre MUAPTs serão discutidas brevemente a seguir.

4.3.2 Aquisição do sinal

Trataremos aqui de algumas técnicas que em sua maioria foram desenvolvidas para decomposição de sinais EMG usando técnicas de aquisição invasivas (eletrodos de agulha e fio), que até então, pelo fato de apresentarem alta resolução espacial, e vantagem de captar a atividade de músculos localizados mais profundamente, mesmo sendo difíceis de se usar na prática, eram as únicas opções quando se pretendia fazer a decomposição de um sinal EMG. Isto não impede que sejam aplicadas na decomposição de sinais EMGS, desde que estes tenham sido adquiridos com resolução suficiente, ou seja, usando eletrodos ativos com distância intereletródica na faixa milimétrica, conforme discutido no tópico 4, sobre filtragem espacial e a EMG-ARE.

4.3.2.1 Protocolo de detecção do sinal

O tipo do eletrodo, o posicionamento do eletrodo, o perfil de contração do músculo e o músculo selecionado todos afetam a qualidade do sinal adquirido. Para assegurar que o sinal obtido tenha suficiente nitidez e uma relação sinal-ruído adequada, o eletrodo deve ser inicialmente posicionado de modo que em uma contração mínima do músculo, os MUAPs detectados tenham um máximo de amplitude e nitidez. Isto garante que o eletrodo está próximo de fibras musculares ativas, que por seu lado são a causa dos MUAPs detectados serem mais distintos com relação ao ruído e a cada uma das várias UMs ativas. Deste modo, a amplitude e nitidez do MUAP são dois fatores chave da qualidade do sinal que devem ser maximizados se possível. O sujeito deve ser então instruído para aumentar o nível de contração do músculo, o mais isometricamente possível, até o nível desejado. Quando o nível de contração desejado é atingido, inicia-se então a aquisição dos dados. A complexidade do sinal a um certo nível percentual de contração (%CVM) está relacionado com alguns fatores fisiológicos tais como: o número de UMs

ativas no músculo, diâmetro da fibra muscular, a densidade de fibras da UM, limiar de recrutamento da UM e estratégias de taxa de codificação da UM. Músculos pequenos, comparados a grandes músculos, tais como o bíceps braquial, tem menos UMs, tendem a ter uma faixa estreita para o limiar de recrutamento e usam altas taxas de codificação. Então, para percentuais de contração comparáveis, pequenos músculos geram em média sinais mais complexos do que os detectados em grandes músculos, (Basmajian & De Luca, 1985).

4.3.2.2 Atributos interessantes do sinal EMG

O sistema ideal para decomposição de sinal EMG deve ser capaz de lidar com sinais com os seguintes atributos:

1. Cinco ou mais MUAPTs;
2. Formas de MUAPs normalmente não-estacionárias devido a movimento do eletrodo;
3. Formas dos MUAPs variáveis devido à variabilidade na operação da junção neuromuscular e ruído de fundo biológico devido à atividade de outras UMs;
4. Duas ou mais UMs com formas similares de MUAPs;
5. Freqüentes superposições de MUAPs;
6. Estatísticas do padrão de disparos da UM não-estacionárias;
7. Recrutamento e decrutamento intermitente das UMs.

4.3.2.3 Seleção da taxa de amostragem

O teorema da amostragem de Nyquist prediz que a taxa mínima com que um sinal pode ser amostrado sem perda de informação é duas vezes a freqüência máxima contida no sinal. Isto sugere que se um sinal é limitado em banda a 5 kHz, uma taxa de amostragem mínima de 10 kHz pode ser usada.

Contudo, se esta taxa mínima fosse usada, técnicas de interpolação, no domínio do tempo ou da freqüência, seriam requeridas para se obter suficiente resolução temporal ao se comparar formas das componentes do sinal e para exibição gráfica adequada. Neste caso, a amostragem a uma taxa de 25 kHz é um compromisso entre superamostragem extrema, que pode requerer equipamento especializado, e amostragem a taxa mínima, que pode requerer interpolação do sinal.

4.3.3 Segmentação do sinal composto (detectando MUAPs)

O primeiro passo na decomposição de um sinal EMG é detectar todos os MUAPs gerados pelas UMs ativas durante a aquisição. Contudo, na pratica, os MUAPs das UMs que não tem fibras próximas à superfície de detecção são de baixa amplitude, compostos primariamente de componentes de baixa freqüência e muito similares na forma. Por isto, é muito difícil indexar tais MUAPs a seu correto MUAPT e é muito fácil a perca da ocorrência de tais MUAPs quando eles ocorrem próximos temporalmente de grandes MUAPs. Conseqüentemente, é necessário selecionar e detectar consistentemente somente os MUAPs que poderão ser efetivamente indexados. Muitos métodos diferentes têm sido inventados para segmentar o sinal em seções que contém MUAPs significantes. Todos esses métodos são baseados na definição de algum tipo de detecção de limiar (threshold) baseado em alguma estatística computada usando o sinal composto. Muitos algoritmos, quando as características do sinal produzem um valor estatístico acima do limiar, selecionam uma seção de comprimento fixo que é subseqüentemente assumido como um MUAP candidato a classificação. Outros métodos selecionam uma seção de comprimento variável, a qual se assume conter contribuições de MUAPs significantes, (Gerber et al., 1984; Guiheneuc et al., 1983; Kadefors et al., 1999; Loudon et al., 1992; Nicolic et al., 1997). De qualquer modo, métodos para determinar o que de fato foi detectado, se foi

corretamente alinhado e representado, devem ser incorporados ao sistema de decomposição para processamento posterior. Isto porque qualquer secção detectada do sinal pode ser realmente um MUAP isolado, a superposição de MUAPs de duas ou mais UMs, somente uma porção de um MUAP isolado, ou um pulso de ruído espúrio.

Alguns esquemas de detecção são aplicados ao sinal bruto ou filtrados em banda e são baseados na amplitude ou no limiar de variância do sinal. Outros, aplicados ao sinal bruto, usam uma combinação da inclinação e do limiar de amplitude. Um método consistente de seleção de segmentos que contêm MUAPs que podem ser corretamente indexados considera a inclinação do sinal após passar por um diferenciador passa-baixas (McGill & Dorfman, 1989; Hassoun et al., 1994; Pattichis et al., 1995).

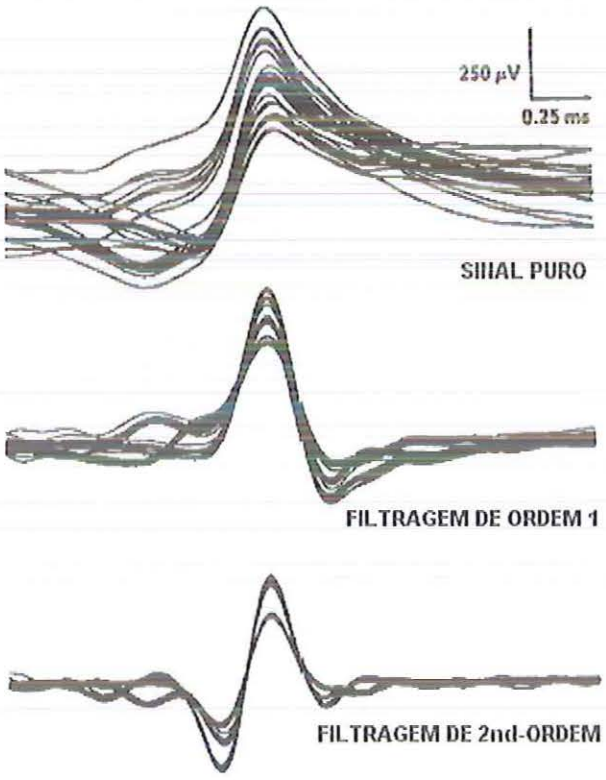

Figura 4.3 – Os efeitos da filtragem passa-banda na forma e distinção dos MUAPs. Nota-se que com a diferenciação passa-baixas os MUAPs têm sua duração reduzida e os MUAPs criados por cada uma das três UMs, aqui contribuintes, podem ser mais facilmente discriminados (Adaptado de McGill & Dorfman,1989).

Em geral, a filtragem passa-banda e a diferenciação passa-baixas encurtam a duração dos MUAPs, o que reduz sobreposição temporal e então reduz o número de formas de onda sobrepostas. Reduzem também a amplitude de muitos MUAPs de formas similares de diferentes MUs que não têm fibras próximas ao eletrodo. Esta filtragem pode remover informação de baixa freqüência não discriminativa, tornando mais fácil discriminar os MUAPs de diferentes MUs reduzindo a variabilidade nas formas dos MUAPs. A Figura 4.3 mostra o efeito da filtragem diferencial de primeira e segunda ordem. Após a filtragem os MUAPs têm sua duração encurtada e o ruído da linha de base é removido.

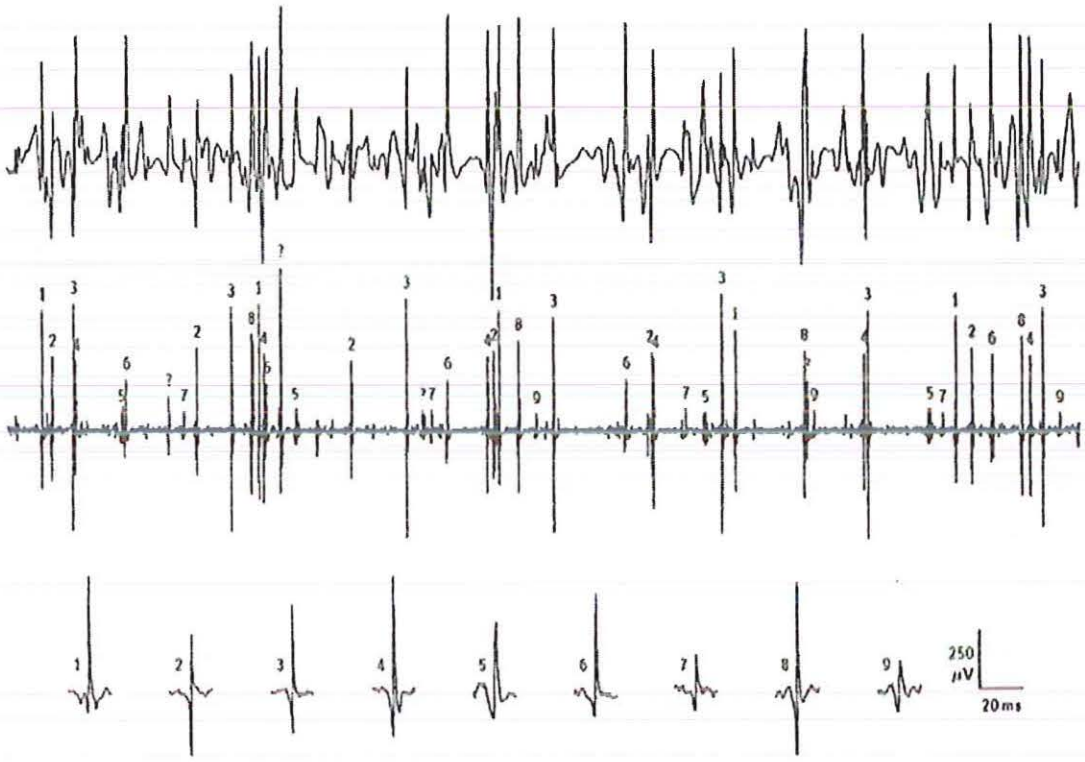

Figura 4.4 – Exemplo de detecção de um sinal EMG que foi diferenciado em passa-baixas. Traço superior mostra um segmento de EMG bruto. O traço do meio mostra o mesmo segmento após passar por um filtro diferenciador passa-baixas de segunda ordem indicando os MUAPs significantes detectados. O traço de baixo mostra as médias das formas de onda das UMs que contribuíram significantemente para o segmento de EMG mostrado (McGill & Dorfman, 1989).

Independentemente de como os segmentos significantes do sinal são detectados de algum modo eles devem ser alinhados. Durante a segmentação,

muitos sistemas inicialmente alinham as formas de onda detectadas usando valores de pico tanto do sinal bruto quanto da inclinação. Contudo, erros de alinhamento podem algumas vezes não ser corrigidos durante as tentativas de alinhamento e causar problemas de classificação. Métodos de alinhamento durante a segmentação, quando se dispõe de pouca informação contextual, precisam ser desenvolvidos e avaliados. A Figura 4.4 mostra uma secção de um sinal EMG que foi filtrado e então segmentado. Neste exemplo os MUAPs detectados também foram classificados. O número abaixo de um MUAP detectado representa o MUAPT ou UM para o qual ele foi indexado.

4.3.4 Extração de características para reconhecimento de padrão

Os MUAPs detectados devem ser representados usando um vetor para reconhecimento de padrão. As características dos MUAPs usados para esta representação formam um espaço multidimensional composto de todas as possíveis características chamado de *espaço característico*.

4.3.4.1 Considerações sobre espaço característico

A seguir tem-se uma lista com vários fatores a serem considerados na decisão do melhor modo para representar um objeto (MUAP) para reconhecimento de padrão.

1. Quais são os requisitos computacionais e de armazenamento dos vetores característicos? (Quantas são as características?);
2. Qual é o esforço computacional exigido para extrair ou computar os valores característicos?
3. Qual é a relação sinal-ruído e a variância de cada característica?
4. Qual a quantidade de correlação entre as características?
5. Qual o poder discriminativo da característica?

6. Qual é a sensibilidade da representação para o alinhamento da forma de onda?
7. Qual é o efeito das superposições de MUAPs sobre os valores característicos?
8. Qual é o efeito da variabilidade de forma do MUAP sobre os valores característicos?

4.3.4.2 Espaços característicos

Um número de diferentes espaços característicos têm sido usados para representar MUAPs para decomposição de sinal. Espaços característicos mais usados são:

1. Estatísticas morfológicas (voltagem pico a pico, área do pico, duração, número de fases, passagens por zero, inflexões,etc.), Figura 4.5;
2. Representação no domínio da freqüência (usando coeficientes da transformada de Fourier);
3. Coeficientes obtidos de uma transformação (ex. Base wavelet);
4. Amostras temporais do sinal filtrado em passa-banda;
5. Amostras temporais do sinal diferenciado em passa-baixas.

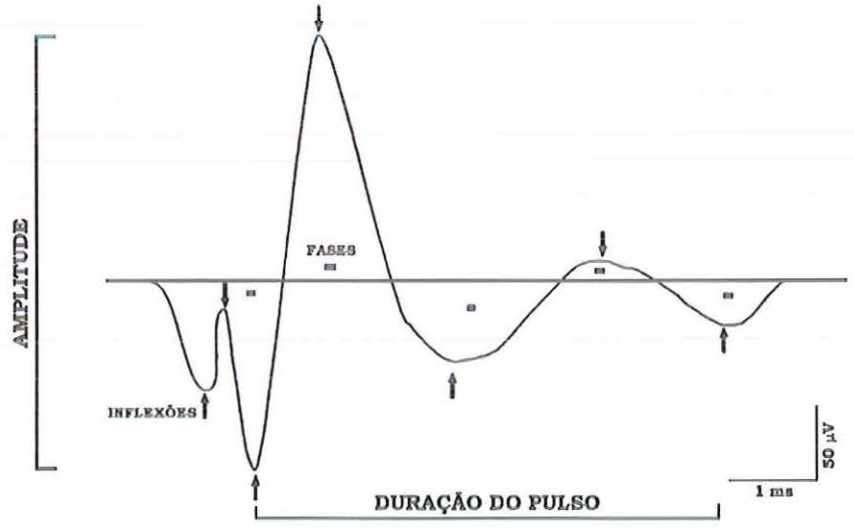

Figura 4.5 - Parâmetros do MUAP no domínio do tempo (estatísticas morfológicas).

4.3.5 Agrupamento dos MUAPs detectados (clustering)

"*Clustering*", em geral é o particionamento de um conjunto de objetos em um número de grupos ou "*clusters*". Qualquer membro de um grupo deve ser mais semelhante aos membros do seu grupo do que aos membros de qualquer outro grupo. O número exato de grupos não é conhecido de antemão, cada agrupamento tem uma forma protótipo que é chamada de cluster médio ou protótipo ("*template*"), que também é desconhecida inicialmente. Dentro do contexto da decomposição de sinal EMG, um algoritmo de agrupamento tem dois objetivos principais. Um é determinar o número correto de UMs contribuindo com MUAPs significantes para o sinal EMG composto (i.e. o número de MUAPTs significantes). O outro é indexar o máximo de MUAPs possível ao seu correto MUAPT, tal que a forma protótipo ou MUAP médio de cada UM possa ser determinada. Contudo, cada MUAP indexado por engano aumenta a probabilidade de mais erros. Por isto, mais do que indexar todos MUAPs detectados é muito importante que os resultados do agrupamento sejam precisos e MUAPs superpostos sejam ignorados. Como tal, o algoritmo de agrupamento não necessita considerar todos MUAPs detectados nem classificar todos MUAPs considerados. Até mesmo porque, durante as fases posteriores da decomposição é mais fácil fundir dois trens em um, que dividir um trem em dois, portanto é preferível subestimar o número de MUAPTs.

4.3.5.1 Medida de distância

Decisões de agrupamento são baseadas em alguma medida de similaridade ou dissimilaridade entre as formas dos MUAPs. A medida mais freqüentemente usada é a distância Euclidiana, definida a seguir.

Seja X_i denotado pelo i-ésimo padrão N-dimensional (MUAP);

$$X_i = (x_{i1}, x_{i2}, \ldots, x_{iN})^T \quad \textbf{(4.7)}$$

A distância euclidiana entre dois objetos em um espaço característico ***N***-dimensional é então:

$$d^2(X_i, X_k) = (X_i - X_k)^T \cdot (X_i - X_k) = \sum_{j=1}^{N} (x_{ij} - x_{kj})^2 \quad \textbf{(4.8)}$$

Se M_k denota a k-ésima média ***N***-dimensional ou protótipo padrão (MUAP) do k-ésimo agrupamento (MUAPT);

$$M_k = (m_{k1}, m_{k2}, \ldots, m_{kn})^T \quad \textbf{(4.9)}$$

A distância euclidiana entre um objeto e um agrupamento médio em um espaço característico ***N***-dimensional é então:

$$d^2(X_j, M_K) \quad \textbf{(4.10)}$$

4.3.5.2 Técnicas de agrupamento clássicas

Técnicas hierárquicas inicialmente assumem que cada objeto é um agrupamento e computam as distâncias entre todos pares de objetos e armazenam o resultado em uma matriz de distâncias. Existem duas técnicas básicas conhecidas como *link* único (ou simples) e completo, respectivamente. Nas técnicas de link completo, os dois objetos mais similares são combinados em um grupo e substituídos por sua forma média. A matriz de distâncias para o número reduzido de objetos é então recalculada. Este processo de juntar objetos e recalcular a matriz de distancias é repetido até que reste apenas um único objeto (grupo). O caminho traçado por este processo cria o chamado dendrograma. Se o dendrograma é cortado em algum nível de dessemelhança, serão criados ***K*** grupos de todos os objetos representados por cada uma das ***K*** formas médias remanescentes, que se assumem pertencerem cada uma ao

respectivo grupo. Estas técnicas são chamadas de link completo porque os objetos são comparados aos valores médios dos grupos e conseqüentemente as decisões de agrupamento são baseadas sobre todos os elementos de qualquer grupo particular. As várias técnicas hierárquicas de link completo se diferem no modo como combinam os objetos e computam seus valores médios. As técnicas hierárquicas de link único são similares as de link completo pelo fato de também usarem uma matriz de distância. Porém, a associação de um membro ao grupo é baseada num único objeto individual mais próximo e não no grupo médio. Este tipo de agrupamento é também conhecido por vizinho-mais-próximo. Ambas as técnicas hierárquicas não dependem da ordem na qual os objetos são considerados para classificação. Porém, todos os dados devem ser considerados de uma vez, o que é computacionalmente caro para grandes conjuntos de dados. Além disso, devem ser escolhidos limiares para o corte do dendrograma e determinação do número apropriado de grupos. Com relação à decomposição de sinais EMG, a seleção de limiares apropriados que sejam adequados para uma ampla variedade de sinais pode ser problemática devido à variedade de sinais EMG que podem ser encontrados.

Uma alternativa clássica as técnicas de agrupamento são os métodos de particionamento. Dado um número conhecido de grupos K, os métodos de particionamento tentam criar um conjunto de partições (C_1, C_2,..., C_K), onde C_i representa o conjunto de objetos que pertencem ao i-ésimo grupo, que minimizam uma função objetivo especificada. Freqüentemente a função a ser minimizada é o erro quadrático definido como:

$$E_k^2 = \sum_{k=1}^{K} e_k^2 = \sum_{k=1}^{K} \sum_{X_i \in C_k} (X_i - M_k)^T \cdot (X_i - M_k) \qquad \textbf{(4.11)}$$

Em todos os métodos de particionamento algum método deve ser usado para determinar o número de partições ou grupos e uma estimativa inicial do grupo médio. Desde que o número de grupos e suas médias iniciais são decididos,

cada objeto é então simplesmente associado ao grupo com a média mais próxima.

$$X_i \in C_c \quad se \quad d^2(X_i, M_c) < d^2(X_i, M_k), \quad k = 1,2,...K, \quad k \neq c \qquad \textbf{(4.12)}$$

O valor médio de cada grupo pode ser atualizado após cada associação ou ao fim um passo através do conjunto de dados. Múltiplos passos através dos dados são requeridos até que os grupos médios atinjam a estabilidade adequada. Nos métodos de particionamento a ordem com que os objetos são classificados pode alterar os resultados. Contudo, somente um objeto e o grupo médio são considerados por vez, o que reduz a complexidade computacional. Dois exemplos clássicos de algoritmos de agrupamento que usam métodos de particionamento são o K-means e o ISODATA (Jain & Englewood, 1988).

Técnicas de agrupamento seqüencial, tal como agrupamentos "baseado-no-líder", podem ser considerados casos especiais dos métodos de particionamento. Estas técnicas executam um passo simples através dos dados usando um objeto inicial considerado como um grupo modelo ou protótipo inicial, e limiares de similaridade fixados para associar os objetos subseqüentes ao modelo mais próximo, atualizam o modelo corrente ou usam o objeto corrente que está sendo classificado para inicializar um novo modelo.

4.3.6 Algoritmos de agrupamento usados para decomposição de sinais EMG

Muitos algoritmos usados para decomposição de sinais EMG têm se baseado nos conceitos de link único ou vizinho-mais-próximo, (Christodoulou et al., 1999; De Luca, 1993; Fang et al., 1999; Gerber et al., 1984; Kadefors et al., 1999; Loudon et al., 1992; Nikolic et al., 1997; etc.). Pattichis et al., 1995, usaram uma modificação da técnica de link completo que não era baseada na

métrica de distância tradicional, mas fizeram melhor, aplicaram critérios de variação para cada parâmetro do MUAP sendo avaliado. Outros têm usado métodos de particionamento tais como o *K-means* (Stashuk & Qu, 1996) e a abordagem *baseada-no-líder* (LeFever & De Luca, 1982; McGill et al., 1985). Redes neurais auto-organizáveis com vetor de quantização de aprendizagem têm sido usados (Christodoulou et al., 1999), bem como redes neurais recorrentes (Hassoun et al., 1994). Para muitas dessas aplicações a distância Euclidiana padrão é de algum modo normalizada pela energia das formas de onda que estão sendo comparadas (Christodoulou et al., 1999; Kadefors et al., 1999; Loudon et al., 1992; LeFever & De Luca, 1982). Guiheniuc (1983), e McGill et al. (1985), ao invés ajustaram os limiares de aceitação baseados no tamanho do MUAP, a distância de normalização e os ajustes dos limiares levam em conta a alta variabilidade biológica esperada para grandes MUAPs. Stashuk & Qu (1996), consideraram uma porção dos MUAPs detectados e usaram ativamente a forma do MUAP bem como a informação do padrão de disparo, estando ela disponível, para determinar o número de MUAPTs e tomar decisões de classificação. A informação do padrão de disparo é calculada usando algoritmos desenvolvidos especificamente para lidar com MUAPTs esparsos, que porventura perderam alguns disparos da UM, podendo ainda incluir disparos errôneos da UM. LeFever & De Luca (1982), valendo-se de uma função de risco, também utilizaram ativamente a informação do padrão de disparo. Muitos outros métodos usam passivamente a informação do padrão de disparo para detectar falsas classificações, classificações errôneas e para a possibilidade de fundir MUAPTs (Gerber et al.,1984; Guiheniuc et al.,1983; Hassoun et al., 1994; Loudon et al., 1992; McGill et al., 1985; Stashuk & Qu, 1996). Várias outras modificações nas medidas de distância têm sido usadas: Gerber et al. (1984), usaram uma medida de distância baseada na área ao invés da energia; Nandekar et al. (1995), primeiro checaram a inclinação máxima e amplitude dos MUAPs a serem comparados, sendo adequadamente similares então sua medida de distância era calculada;

Fang et al. (1999), usaram apenas a diferença máxima entre os coeficientes correspondentes de uma transformada wavelet.

Um dos aspectos mais importantes de qualquer algoritmo de agrupamento são os limiares usados para cortar os dendrogramas, seja para determinar o número de grupos, tomar decisões de classificações dos MUAPs candidatos ou então para inicializar novos protótipos. Isto se deve as formas de onda superpostas dos MUAPs que estão sendo considerados na classificação, as quais devem ser identificadas para subseqüente resolução e não devem ser usadas para atualizar os grupos modelos. Nesta consideração, muitos métodos usam um limiar fixado à priori baseado na semelhança de forma (Christodoulou et al., 1999; LeFever & De Luca, 1982; McGill et al., 1985; Pattichis et al., 1995), padrão de disparo (Fang et al. ,1999), ou ambos (Kadefors et al., 1999; Nandekar et al.,1995). Alternativamente alguns métodos usam limiares que são dependentes de um sinal EMG especifico que está sendo decomposto (Gerber et al.,1984; Hassoun et al., 1994; Loudon et al., 1992; Nikolic et al., 1997). Em geral, limiares dirigidos pelos dados levam a uma performance mais robusta através da multiplicidade de sinais EMG. Essencialmente em todos os casos um número mínimo de ocorrências dentro de um MUAPT são usadas na validação do trem e na identificação de formas de onda superpostas. A Figura 4.6 ilustra resultados típicos de um algoritmo de agrupamento.

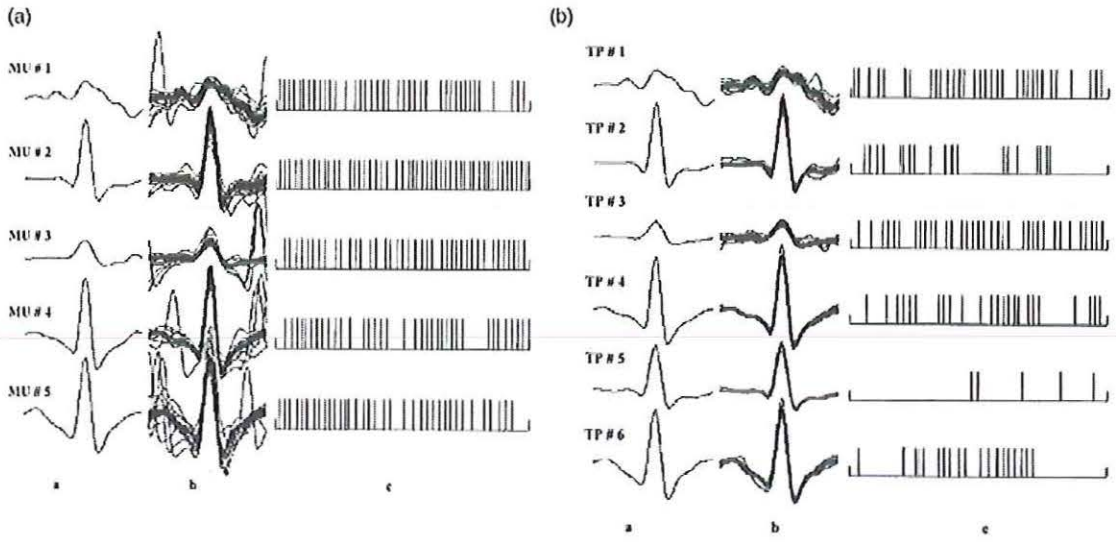

Figura 4.6 - Exemplo da saída de um algoritmo de agrupamento que usa a informação da forma de onda do MUAP e do padrão de disparo da UM. Para um intervalo analisado de 5 s; (a) Resultados padrões determinados manualmente; (a) Formas protótipos; (b) MUAPs associados; (c) Padrão de disparo da UM. Falhas no padrão de disparo são causadas por superposições de MUAPs não resolvidas. (b) Resultados do algoritmo de agrupamento. (a), (b) e (c) idem (a). Os grupos 2 e 5 estão duplicados e juntos representam a atividade da UM #2. Eles foram criados devido a não estacionaridade do sinal e podem ser fundidos por um algoritmo de classificação supervisionada [Nandedkar et al., 1995].

4.3.7 Classificação supervisionada dos MUAPs detectados

Algumas técnicas de decomposição aplicam métodos de classificação supervisionada, associados ou não a métodos de agrupamento (De Luca, 1993; Gerber et al.,1984; Guiheneuc et al., 1983; Hassoun et al., 1994). Em geral, algoritmos de classificação supervisionada usam um conjunto de objetos associados para caracterizar o número esperado de classes e as propriedades de cada classe, tal que objetos porventura não associados possam ser associados com mais eficiência. Portanto, uma vez que estimativas do número de UMs ativas e as formas de seus MUAPs protótipos estão disponíveis (estas estimativas são usualmente baseadas nos resultados de agrupamento) o conjunto completo dos MUAPs detectados podem ser classificados usando técnicas de classificação supervisionada.

Os passos básicos que podem possivelmente ser aplicados na classificação supervisionada são descritos a seguir:

1. Verificar erros óbvios nos resultados do agrupamento;
2. Selecionar o espaço característico e/ou características mais discriminativas;
3. Derivar protótipos mais efetivos para cada classe;
4. Derivar limiares para similaridade de forma aos dados ajustados;
5. Estimar as estatísticas do padrão de disparo para cada classe;
6. Tentar classificar MUAPs não associados dados os protótipos e os padrões de disparos para cada classe;
7. Dadas as novas classificações, atualizar os protótipos e as estatísticas dos padrões de disparos para cada classe;
8. Unir as classes que são presumivelmente oriundas mesma UM;
9. Dividir as classes que contêm MUAPs presumivelmente de mais que uma UM;
10. Repetir os passos 6, 7, 8 e 9 até que não haja mais classificações a serem feitas.

4.3.7.1 Fatores que afetam a classificação supervisionada

Dois fatores principais afetam a performance da classificação supervisionada, são eles: a variabilidade dos MUAPs contidos nos MUAPTs bem como a similaridade entre MUAPs de diferentes trens. A variabilidade nas formas dos MUAPs é causada por duas condições principais, ruído e não-estacionaridade do sinal. A principal fonte de interferência é causada por MUAPs de outras UMs que estão ativas ao mesmo tempo ou próximas temporalmente do MUAP detectado. Isto inclui algumas poucas UMs com fibras próximas do eletrodo detector e causa a chamada superposição de MUAPs, bem como um grande número de UMs ao longo de todo o músculo que contribuem com ruído de fundo temporalmente difuso. A segunda fonte de

ruído, que é gerado inteiramente dentro da UM e é evidente mesmo se uma única UM está ativa, se deve à variabilidade no tempo requerido pela junção neuromuscular para despolarizar as membranas das fibras musculares "*jitter*". Esta variabilidade resulta em tempos diferentes para os MFAPs constituintes de um MUAP que chegam ao eletrodo e causam variações na forma do MUAP a cada disparo. Esta variação biológica é algumas vezes chamada de "*jiggle*" ou dança. A terceira e menor de todas fontes de ruído se deve a instrumentação requerida para amplificar as voltagens detectadas. A não-estacionaridade do sinal ocorre se o eletrodo se move em relação às fibras, e aparece como uma tendência de mudança na forma dos MUAPs com o passar do tempo. Apesar das diversas fontes de variabilidade na forma do MUAP, os MUAPs de duas UMs distintas podem ser ainda notavelmente semelhantes se elas têm fibras musculares geometricamente semelhantes. Os algoritmos de classificação supervisionada devem ser aptos a lidar com esta variabilidade na forma do MUAP dentro de um MUAPT e discriminar consistentemente MUAPs semelhantes gerados por UMs diferentes.

Um fator de performance adicional a se considerar é a informação do padrão de disparo. Se um algoritmo de classificação supervisionada usa a informação do padrão de disparo, tanto passivamente quanto ativamente, tem que levar em conta também os fatores que afetam a validade de qualquer estimativa estatística do padrão de disparo, tais como: taxa de erro de classificação e identificação; número mínimo de IPIs na amostra de estimação; e a variabilidade inerente do padrão de disparo no intervalo de estimação. Portanto, os intervalos de estimação usados para determinar as estatísticas do padrão de disparo devem considerar a estacionaridade dos padrões de disparo, isto é obviamente muito importante quando se está analisando sinais detectados durante forças de contrações variáveis. Além disso, o grau no qual a informação do padrão de disparo é usada na tomada de decisão para classificação, deve equiparar o nível de confiança sobre a informação usada.

Muitos dos métodos de decomposição de EMG reportados não usam um algoritmo de classificação supervisionada. Ao invés, eles tentam classificar todos os MUAPs usando somente técnicas de agrupamento. Gerber et al. (1984) e Guiheniuc et al. (1983), entretanto, usam um algoritmo de classificação supervisionada de passo-único para classificar MUAPs descobertos em segmentos do sinal de comprimento variável; Hassoun et al. (1994), usam uma rede neural treinada para classificar MUAPs individuais. Cada um desses algoritmos usa os resultados de um estágio inicial de agrupamento para ajudar em tomadas de decisões na classificação supervisionada.

4.3.8 Resolução de MUAPs superpostos

Durante a contração do músculo as UMs disparam assincronamente e a taxas de disparo variáveis, dependendo do limiar de recrutamento das UMs e do nível da força de contração produzida pelo músculo. Quando duas ou mais UMs disparam ao mesmo tempo ou em curta sucessão temporal, o potencial detectado é a soma algébrica dos potenciais individuais das UMs, então se diz que é um MUAP superposto. Durante a decomposição do sinal EMG, caso a informação completa do padrão de disparo precise ser obtida, os MUAPs superpostos precisam ser resolvidos em seus MUAPs constituintes. Três tipos diferentes de formas de onda superpostas podem ser definidos: *parcialmente superposto*, na qual os MUAPs se superpõe sem que os picos fiquem encobertos; *completamente superposto,* os picos dos MUAPs se combinam para formar um amplo e único pico; e *destrutivamente superposto*, na qual os MUAPs superpõe-se estando com seus picos fora de fase de tal modo que se cancelam mutuamente. A Figura 4.7 ilustra os vários tipos de superposição de MUAPs.

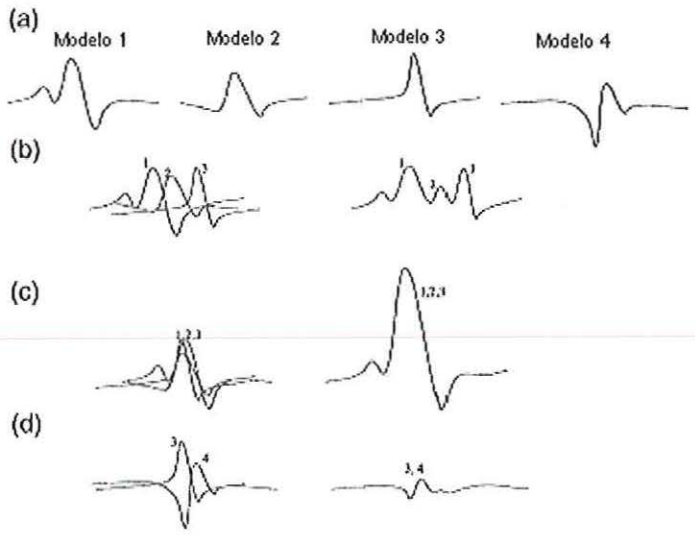

Figura 4.7 - Definições de superposição de MUAPs. São ilustradas quatro formas de onda de MUAPs e suas superposições para diferentes deslocamentos no tempo. (a) Formas de onda dos MUAPs; (b) superposição parcial; (c) superposição completa; (d) superposição destrutiva.

As tentativas de resolução de MUAPs superpostos podem ser baseadas em duas estratégias fundamentalmente diferentes. A primeira é conhecida como "*peel-off*" (casca externa) ou abordagem seqüencial, que é baseada no emparelhamento dos MUAPs modelos, um de cada vez, com a forma de onda superposta ou a forma residual dela. Se um emparelhamento é satisfatório o MUAP é assumido ter contribuído para a superposição e subtraído dela. A forma de onda residual criada é então usada para procurar por outros MUAPs modelos contribuintes. As contribuições dos MUAPs podem ser assumidas estarem corretas após cada subtração ou o resíduo final pode ser usado para aceitar a combinação de MUAPs subtraídos. Alguns algoritmos usando a abordagem "*peel-off*" são reportados em: Christodoulou & Pattichis (1999); Fang et al. (1999); Guiheneuc et al. (1983); Kadefors et al. (1999); e LeFever & De Luca (1982).

A segunda estratégia e conhecida como "*modelling*", ou modelagem, e se baseia na síntese de modelos de formas de onda superpostas, através da adição de combinações de MUAPs protótipos com diferentes

deslocamentos relativos no tempo. A síntese e comparação de modelos são repetidas até que um emparelhamento ótimo ou aceitável é obtido entre um dos modelos de formas de onda superpostas e o MUAP superposto real. A abordagem "*peel-off*" não é muito poderosa quando as formas de onda superpostas exibem propriedades destrutivas, enquanto que a abordagem "*modelling*" é teoricamente capaz de resolver todos os tipos de formas de onda superpostas. A abordagem "*peel-off*", contudo, é mais rápida do que a "*modelling*". Ela requer *2NM* testes para resolver um MUAP superposto, enquanto que a abordagem "*modelling*" requer $N(N-1)M^2/2$, onde N é o número de contribuições possíveis de UMs e M é o número de deslocamentos temporais considerados por emparelhamento. Diversas abordagens usando "*modelling*" têm sido reportadas dentre elas citamos: De Figueiredo & Gerber (1983); Gerber et al. (1984); McGill et al. (1985); Loudon et al. (1992); Nikolic et al. (1997). Todas essas técnicas se assemelham na redução do espaço de busca requerido, primeiramente selecionam um subconjunto de possíveis MUAPs contribuintes, limitando o número assumido de MUAPs contribuintes a 2 ou 3, em seguida alinham os MUAPs usando algum dos valores de pico ou a máxima correlação, e então usam técnicas de otimização para resolver os parâmetros do modelo. A forma de onda superposta é resolvida usando o melhor ajuste, modelo otimizado. A Figura 4.8 ilustra a resolução de alguns exemplos de MUAPs superpostos.

Algoritmos para resolução de MUAPs superpostos não são essenciais no uso clínico da decomposição de sinais EMG, quando apenas a taxa de disparo média e a variabilidade da taxa de disparo durante contrações constantes estão sendo estudadas. Contudo, conforme o uso da informação do padrão de disparo se torna mais importante aumenta a importância clinica de resolver os MUAPs superpostos, e se dispondo de capacidade computacional, chega a ser mais prático considerar a sua resolução.

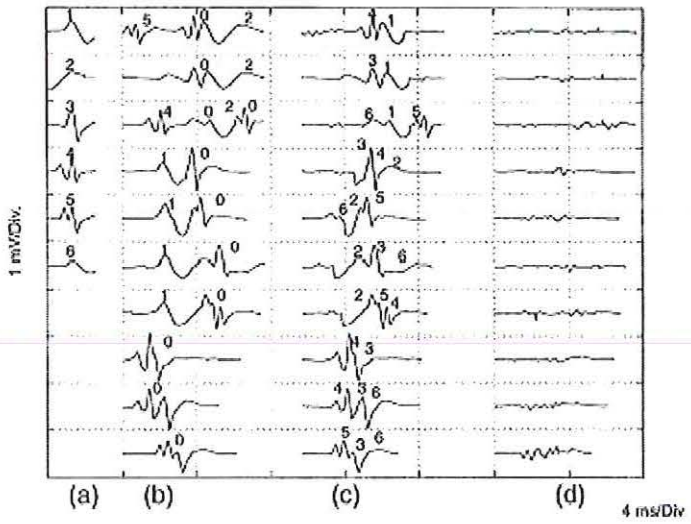

Figura 4.8 - Exemplo de resolução de superposição de MUAPs: (a) Forma de onda modelo candidata; (b) segmentos do sinal contendo um MUAP superposto e outro classificado; (c) MUAPs superpostos resolvidos com outros classificados; (d) resíduos.

4.3.9 Descobrindo relações temporais entre MUAPTs

Durante e após o processo de classificação do MUAP é importante determinar a relação temporal entre MUAPTs. MUAPTs podem ser modelados como um processo estocástico ponto. Se cada descarga de uma UM é independente dos disparos passados e futuros e identicamente distribuída, seu MUAPT pode ser modelado como um processo ponto renovado (Gath, 1974). Esta modelagem representa os tempos de descarga ou intervalos entre tempos de descarga de MUAPTs como variáveis randômicas, (Perkel & Gerstein, 1967). As variáveis randômicas representam a atividade de dois MUAPTs que podem ser independentes ou dependentes. Se eles são independentes, os tempos de disparo de um trem não afetam ou não estão relacionados aos tempos de disparos do outro trem. Por outro lado, se os trens são dependentes, os tempos de disparo de um trem são afetados ou relacionados aos tempos de disparo do outro trem.

4.3.9.1 Definindo e medindo a interdependência entre MUAPTs

Três tipos de comportamento dependente podem ser definidos, são eles: *encadeado, exclusivo e sincronizado.* Trens encadeados disparam com um intervalo definido e essencialmente constante em relação um ao outro, como quando um único MUAP de longa duração é múltiplas vezes detectado como dois ou mais MUAPs distintos, cada um representando uma porção do MUAP longo. Trens exclusivos nunca disparam juntos. Isto quer dizer que a diferença absoluta entre os tempos de disparo de dois MUAPs quaisquer, selecionados de trens, diferentes nunca é menor que alguma quantia de limiar (25 ms, por exemplo). Se dois trens são exclusivos eles podem ter sido criados pela mesma UM e erroneamente separados em dois trens pelo algoritmo de classificação. Trens sincronizados têm comportamentos situando-se entre encadeado e exclusivo, e provavelmente representam a verdadeira tendência biológica das UMs a ter comportamentos de disparos dependentes. Perkel & Gerstein, (1967) estudaram relações entre trens de pulsos usando histogramas de recorrência, mas esta análise requer suposições relativas à distribuição de probabilidades dos histogramas resultantes. Informação mútua é uma medida não-paramétrica de interdependência entre duas variáveis randômicas. A tendência de dois MUAPTs dispararem juntos ou não pode ser determinada pelo estudo das probabilidades de um ou outro MUAPT ou ambos dispararem dentro de uma janela de análise randomicamente posicionada no tempo. Considerando a duração média dos MUAPs e a taxa de disparo máxima, uma janela de 25 ms é suficiente (Bischoff et al., 1994). Uma variável randômica discreta, representando o evento de um MUAPT disparando dentro de uma janela de análise, pode ser definida tendo valor 1 se o MUAPT tem disparos dentro da janela de análise e 0 em caso contrário. Assumindo A e B como variáveis randômicas discretas representando o $MUAPT_i$ e o $MUAPT_j$ respectivamente, de um par de trens selecionados, a interdependência redundante dos trens pode ser medida. A interdependência redundante pode

ser usada então junto com o trem individual e as probabilidades conjuntas para determinar se os trens são independentes ou dependentes e se dependentes se eles são mutuamente exclusivos ou encadeados.

4.3.9.2 Importância da descoberta das relações temporais entre MUAPTS

Pelo fato de se usar um número fixo de amostras para representar um MUAP, porções complexas de MUAPs de longa duração podem ser detectadas como MUAPs separados. Desvendar tais MUAPs multiplamente detectados simplifica o agrupamento e a classificação supervisionada. Contudo, algoritmos que descobrem relações temporais entre MUAPTs , cujos MUAPs representam porções de MUAPs multiplamente detectados, devem ser aplicados para determinar o número correto de UMs ativas. Além disso, durante a detecção não há informação contextual disponível para permitir o alinhamento eficiente do MUAP. Como tal, se um MUAP tem dois picos de amplitude similar com aproximadamente menos de 1ms de separação temporal, uma ligeira variação biológica na forma do MUAP pode ocasionar variação no pico usado para definir o tempo de disparo e, por conseguinte no alinhamento do mesmo. Isso também pode ocorrer para picos de MUAPs isolados se a variabilidade biológica for grande. A busca exaustiva de alinhamento pode superar estes problemas de detecção, todavia é computacionalmente caro. Em geral é mais eficiente processar MUAPTs contendo tais MUAPs multiplamente detectados com algoritmos dedicados que determinam qualquer relação temporal existente entre MUAPTs. A informação mútua baseada na medida de interdependência redundante descrita acima permite encontrar pares de trens associados a MUAPs multiplamente detectados e em seguida fundi-los em um único trem. Assim, a aplicação de um algoritmo para descoberta de relações temporais permite casar o número de MUAPTs descobertos na decomposição do sinal, aproximando-o ao

número de UMs que contribuíram consistentemente com MUAPs significantes para o sinal EMG composto. Todavia, em algumas situações de pesquisa o uso excessivo de tal informação temporal pode não ser apropriado.

4.3.10 Avaliação da decomposição do sinal EMG

A precisão, extensão e rapidez com as quais um sistema pode decompor um sinal EMG são os critérios mais importantes para avaliação. A precisão se refere à porcentagem de MUAPs corretamente associados. A extensão se refere à porcentagem do número total de MUAPs que contribuíram para o sinal composto que são realmente detectados e associados, incluindo a resolução de MUAPs superpostos. A rapidez se refere simplesmente ao tempo requerido para a decomposição e subseqüente pós-processamento, incluindo o tempo de máquina e o tempo do operador. Quais destes critérios vem a ser mais importante depende da área de aplicação. Para uso clínico, precisão e rapidez são mais importantes. Para aplicações de pesquisa, precisão e extensão podem ser mais importantes.

4.3.10.1 Avaliação quantitativa

Para a avaliação quantitativa de sistemas de decomposição de sinal EMG e como um meio de obter a decomposição correta e completa (pelo menos para os limites de um operador experiente), foram desenvolvidos sistemas gráficos de visualização auxiliado por computador para decompor manualmente os sinais EMG (Fang et al.,1999; Gerber et al., 1984; Gut & Moschytz, 2000; Loudon et al., 1992; LeFever & DeLuca, 1982). Esses algoritmos são usados para criar um "padrão de ouro" que serve de referência para os arquivos de decomposição. Eles permitem solucionar MUAPs superpostos e apenas a experiência e perseverança do operador limita a precisão dos resultados obtidos. Os resultados editados dos arquivos de saída

(padrão de ouro) podem então ser comparados aos resultados dos arquivos criados automaticamente por um algoritmo de decomposição para determinar a precisão e a extensão da decomposição do sinal. Uma outra abordagem alternativa para validação da decomposição de sinais EMG reais, usada por LeFever e DeLuca (1982), consistia em decompor independentemente dois sinais detectados simultaneamente por eletrodos separados, colocados perto um do outro em um músculo contrátil. Os trens comuns descobertos em cada sinal foram comparados e qualquer discrepância entre eles foi considerada como erro. Esta abordagem é biologicamente mais consistente, no entanto requer um protocolo de aquisição bastante complexo, além de consumir tempo considerável. Os sistemas de decomposição precisam ser avaliados usando sinais normais bem como sinais patológicos. Porém, até a presente data são poucos os sistemas testados usando sinais patológicos (Hassoun et al., 1994). Muitos sistemas de decomposição também têm sido avaliados usando sinais EMG simulados (Fang et al., 1999; Hassoun et al., 1994; Loudon et al., 1992; LeFever & DeLuca, 1982; McGill et al., 1997). O uso de dados simulados é a única forma de ter informação inquestionável sobre a composição real dos sinais decompostos. Conseqüentemente, o uso de dados simulados provê resultados de performance precisos. Contudo, o grau para o qual os sinais simulados se igualam aos dados reais, em especial com relação à variabilidade do MUAP dentro dos MUAPTS, podem em alguns casos limitar sua utilidade. Um novo algoritmo desenvolvido especialmente para avaliação de algoritmos de decomposição pôde superar a maioria destas desvantagens (Farina et al., 2001). No entanto, se avaliando com dados reais ou simulados, o mais importante é a consistência no desempenho do sistema através de uma variedade representativa de sinais.

4.3.10.2 Avaliação qualitativa

A avaliação qualitativa da suficiência de uma decomposição pode ser feita diretamente pela visualização em um diagrama temporal dos MUAPs associados a cada MUAPT conforme ilustra a Figura 4.9. A partir do diagrama pode-se aproximar o número de erros de associação, no entanto este método exige um operador experiente além de demandar tempo considerável.

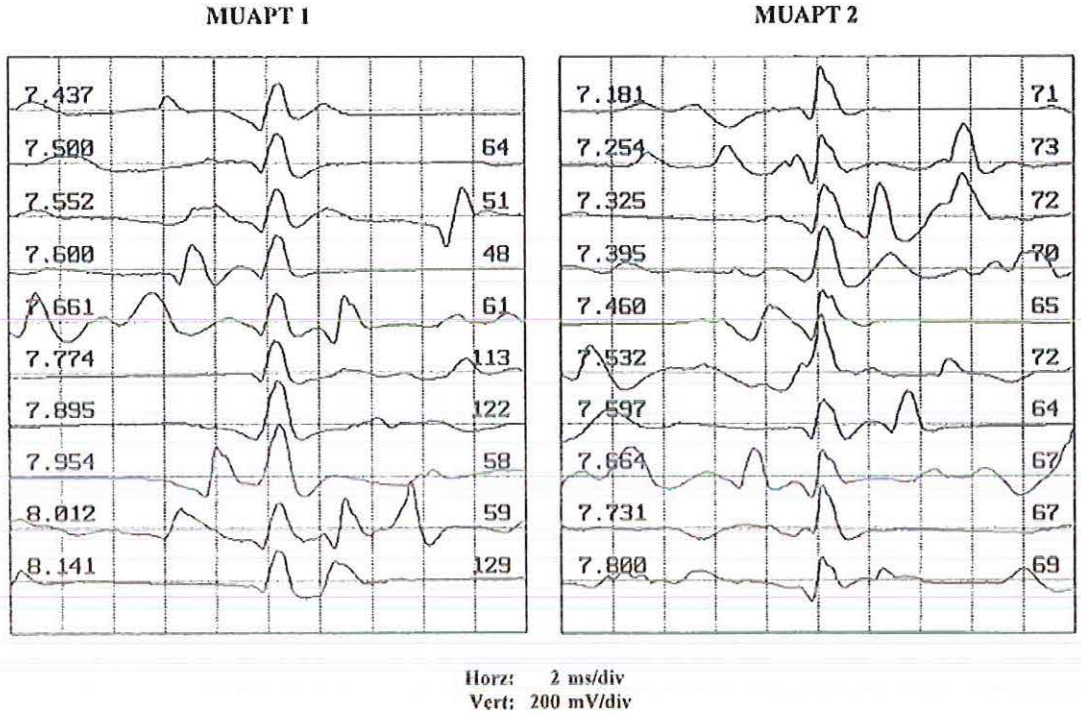

Figura 4.9 - MUAPs similares em dois MUAPTs diferentes. Diagrama temporal com os MUAPs alinhados. O tempo de disparo em segundos é mostrado no lado esquerdo de cada diagrama e o IPI em ms no lado direito. Os MUAPs em cada trem são similares na forma e a informação do padrão de disparo é útil na discriminação entre MUAPs criados por cada UM.

Um outro modo mais prático de se avaliar qualitativamente a decomposição de sinais EMG é através da visualização dos histogramas de IPIs (intervalo entre disparos), e da estimativa da taxa de disparo instantânea como função do tempo, conforme ilustra a Figura 4.10. MUAPTs que contêm muitos erros apresentam grandes variações em seus IPIs e especialmente em sua taxa de disparo instantânea como função do tempo. Se dois trens foram erradamente fundidos em um, isto pode muito freqüentemente ser visto pela

observação dos histogramas de IPIs e das taxas de disparo. Entretanto, em algumas situações de pesquisa o uso dos histogramas de IPIs não será útil por assumir padrões de disparo pseudo-regulares, o que pode não ser apropriado.

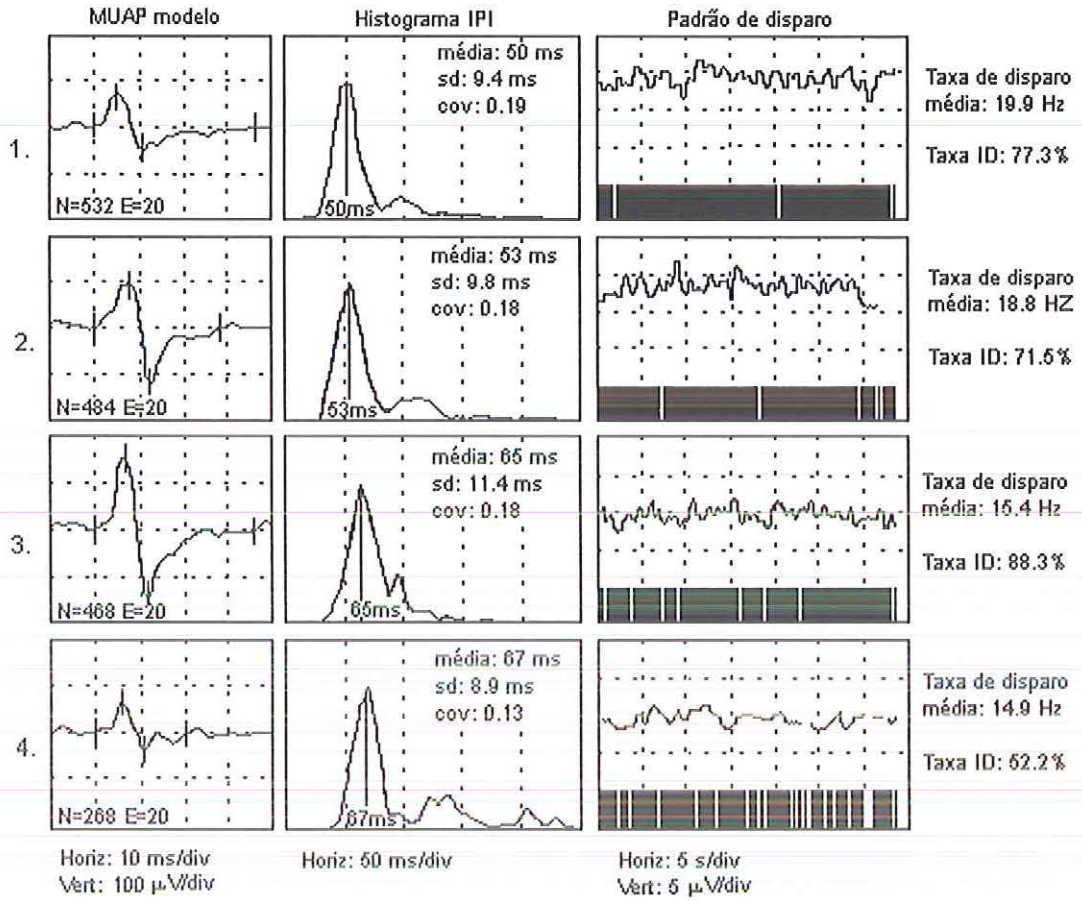

Figura 4.10 - Resultados da decomposição de um sinal EMG típico com subseqüente análise. A primeira coluna mostra para cada MUAPT o MUAP protótipo (modelo) com o número de MUAPs isolados contidos no trem e usados para sua estimação. A segunda coluna apresenta os histogramas de IPIs com a média, desvio padrão e coeficiente de variação do máximo principal. A terceira coluna mostra o MUAPT com seus tempos de disparo e respectiva taxa de disparo instantânea, ao lado é mostrada a taxa média de disparo de cada UM (adaptado de Nandedkar et al., 1995).

4.4 Usando os resultados da decomposição

Os resultados da decomposição de um sinal EMG podem ser usados para auxiliar no diagnóstico, tratamento e estudo de desordens neuromusculares do ponto de vista funcional. Mais ainda, informação sobre a operação e controle dos músculos esqueléticos, efeitos de doenças, envelhecimento e fadiga muscular podem ser obtidos. A seguir são descritos alguns de seus usos mais comuns.

4.4.1 Doenças e alterações morfológicas nos MUAPs

Em músculos normais as fibras da UM estão distribuídas randomicamente por uma área circular em torno de 5-10 mm de diâmetro chamada de domínio da UM. A morfologia das UMs de um músculo se altera com as doenças. Nas miopatias, o número de UMs é reduzido, mas o tamanho das UMs remanescentes é aumentado. Isto significa que a UM passa a ter um grande número de fibras e que as fibras não estão mais distribuídas randomicamente no espaço de domínio da UM. Estas mudanças morfológicas na estrutura das UMs resultam em mudanças na forma de seus MUAPs (Basmajian & DeLuca, 1985). A caracterização dessas mudanças pode ser usada para auxiliar o diagnóstico e tratamento de algumas desordens neuromusculares (Barkhaus et al. 1990; Bischoff et al., 1994; Howard et. Al., 1988; McGill & Dorfman, 1985; Nadedkar et al., 1995; Pattichis et al., 1995; Pfeiffer & Kunze, 1995; Sonoo & Stalberg, 1993; Stalberg & Sonoo, 1994). Diversas estatísticas morfológicas do MUAP, calculadas a partir de uma amostra representativa dos MUAPs detectados em um músculo de interesse, são usadas para quantificar suas características (Stalberg et al., 1996). O tamanho de uma amostra típica gira em torno de 20 MUAPs.

Portanto, dado um conjunto de MUAPTs, um para cada UM que contribuiu com MUAPs significantes para o sinal composto original, a forma do MUAP protótipo pode ser estimada pela média das formas dos MUAPs dentro da amostra. Algumas técnicas estatísticas têm sido usadas para reduzir a interferência de outras UMs quando se estima o MUAP protótipo, como a média e mediana (Nandedkar et al, 1995), a moda (Stashuk & Qu, 1996), estatísticas (Stalberg & Sonoo, 1994) e cancelamento de interferência (McGill et al., 1985). Dado um MUAP protótipo, sua duração, voltagem pico a pico, número de fases e inflexões, área e razão área/amplitude podem ser calculados usando algoritmos padrões (Stalberg et al., 1996) e, por conseguinte usados para caracterizar o MUAP tal que os efeitos patológicos possam ser detectados (Pffeifer & kunze, 1995). Os parâmetros morfológicos estimados do MUAP fornecem importantes informações clínicas. Contudo, devido aos diferentes procedimentos de amostragem e estimação envolvidos com os métodos baseados na decomposição, é conveniente que dados normativos separados sejam coletados para comparação quando decisões clínicas devem ser tomadas (McGill & Dorfman, 1985).

4.4.2 Disparos da unidade motora e padrões de recrutamento

Antes da informação do padrão de disparo da UM ser usada ou interpretada, as limitações do sistema de decomposição devem ser levadas em conta. O nível de desempenho esperado dos algoritmos de decomposição com relação à precisão e perfeição, se os algoritmos de decomposição solucionaram MUAPs sobrepostos, se foi feita ou não a edição manual, vai determinar a precisão e perfeição da informação do padrão de disparo disponível. Isto em troca determinará como as informações podem ser usadas. Se a informação é completa e precisa a análise detalhada do padrão de disparo pode ser executada. Se os dados do padrão de disparo não estão completos ou contém erros o nível de análise podem ser limitados ao estudo de valores

médios e variabilidades. Enquanto informações sobre valores médios e variabilidades podem ser satisfatórias para uso clínico, em pesquisa é mais provável que informação mais detalhada seja requerida para embasamento das investigações. Uma vez que a qualidade esperada dos dados de padrão de disparo está determinada, o nível e o tipo de contração durante a aquisição do sinal são outras considerações importantes quando se interpreta a informação do padrão de disparo. A taxa de disparo estava mudando para criar um perfil de força variado? As UMs estavam sendo recrutadas ou decrutadas? Obviamente, se a força de contração também é medida informações mais detalhadas podem ser obtidas. Não obstante, o movimento do eletrodo que leva ao desaparecimento "aparente" e possível "reaparecimento" dos MUAPs deve ser considerado quando se determina o recrutamento e decrutamento de UMs. Fundamentalmente, se o sinal não é estacionário com respeito à forma do MUAP, é difícil determinar confiantemente o recrutamento ou decrutamento.

Considerando as limitações acima, muitos estudos sobre os padrões de disparo da UM foram concluídos com sucesso e conduziram aos seguintes conceitos sobre o controle da UM durante força constante ou contrações isométricas variando lentamente (Basmajian & De Luca, 1985; Conwit et al., 1998; De Luca et al., 1996):

- Tração conjunta e o "efeito casca de cebola";
- Decaimento da taxa de disparo e a diversificação do músculo (músculos grandes versus pequenos);
- Sincronização e interdependência entre trens (efeitos de doenças, envelhecimento e fadiga);
- UM individual e contenção da taxa de disparo média.

As propriedades de controle da UM também foram estudadas durante contrações dinâmicas (kadefors et al,1999) em sujeitos idosos (Erim et al.,1999) e em sujeitos sofrendo de desordens neuromusculares (Dorfman et al., 1989; Gemperline et al., 1995). Em todas essas situações o uso de um sistema de decomposição satisfatório pôde facilitar enormemente o processo.

Em geral, para cada MUAPT obtido, o padrão de disparo básico da UM pode ser caracterizado por um histograma IPI juntamente com as estimativas da média, do desvio padrão (STD) e do coeficiente de variação (CV) de seus IPIs. Considerando que possíveis erros e disparos perdidos possam estar presentes no trem, uma técnica que reconhece e ignora IPIs errôneos deve ser usada. Se os padrões de disparo variam significantemente com o tempo, é importante selecionar um intervalo de análise adequado para garantir estacionaridade durante o intervalo de análise e para mover o intervalo de análise trilhando as mudanças nos padrões de disparo. Durante os intervalos de análise estacionários, as taxas médias de disparo da UM podem ser calculadas como o inverso do IPI médio corrente. A taxa de disparo instantânea da UM, a cada um de seus tempos de disparos, pode ser estimada como o inverso da média ponderada de Hamming de 10 IPIs válidos centrados em torno do tempo de disparo corrente; onde um IPI válido tem um valor menor que 3 STDs do IPI médio corrente. Como um exemplo, a Figura 4.10 ilustra, para cada MUAPT obtido, os tempos de disparos da UM, a taxa de disparo instantânea, o histograma IPI e o cálculo das estatísticas do padrão de disparo. Adicionalmente, é mostrada a *taxa de identificação* (ID), calculada como a porcentagem dos disparos esperados detectados, onde o número de disparos esperados é estimado como o produto da taxa média de disparos pelo tempo que a UM esteve ativa.

Média, STD e a taxa de disparo média dependem do nível de força gerada. Para avaliações clínicas, precisam ser desenvolvidas formas de

padronizar o nível de força gerada durante a aquisição do sinal, sem a necessidade de instrumentação adicional. Para dados níveis padronizados de produção de força, valores incrementados ou reduzidos de vários parâmetros do padrão de disparos são esperados para diversas desordens clínicas. Como tal estes parâmetros podem ser indicadores úteis de estados patológicos específicos. Em todo caso, assumindo um nível constante de força ou analisando pequenos intervalos estacionários do sinal durante uma força de contração variável, o valor do *CV* pode ser usado como uma medida de estabilidade do controle neural ou da habilidade das UMs se manterem constantemente ativas. Os padrões de disparos das UMs foram estudados de modo semelhante em hemipareses (Gemperline et al., 1995), essas técnicas poderiam ser usadas para estudar os efeitos de outras desordens neuromusculares, como atestam vários trabalhos recentes.

4.5 O status atual da decomposição de sinais EMG

A decomposição de sinais EMG é um processo complicado que requer várias etapas de processamento de sinal e reconhecimento de padrões. Os resultados da decomposição de sinais EMG podem ser usados em uma variedade de formas e quantidades abundantes de informações úteis podem ser obtidas. Muitas abordagens diferentes para decomposição de sinal EMG têm sido reportadas e novos sistemas estão atualmente em desenvolvimento. Varias destas abordagens, com foco em aplicações clínicas, têm resultado no desenvolvimento de algoritmos que estão sendo utilizados com relativo sucesso, (Fang et al., 1999; Hassoun et al., 1994; McGill et al., 1997; Nandedkar et al., 1995; Nikolic et al., 1997, Stashuk, 1999). Até o presente, estes sistemas provêem um método robusto para coletar informação quantitativa útil do ponto de vista clínico, no entanto foram desenvolvidos para a EMG de agulha, e talvez por isso não têm tido a aceitação esperada. A

despeito de a EMG superficial ser mais apropriada para aplicações clínicas, não há até o presente momento um método satisfatório para decomposição do sinal EMG de superfície, razão pela qual seu uso em clínica ainda é limitado. No entanto, recentes desenvolvimentos no uso da EMG de superfície tem mostrado que técnicas de aquisição especializadas podem aumentar a resolução espacial do sistema de detecção possibilitando a detecção não-invasiva da atividade individual da UM (Merletti & De Luca 1989; Rau & Disslhorst-Klug 1997; Disslhorst-Klug et al 2000). A maioria dos sistemas clinicamente orientados, num esforço para tornar a decomposição clinicamente aceitável, bem como para reduzir o tempo de análise, não tentam resolver os MUAPs superpostos. Com a disponibilidade de processadores crescentemente mais rápidos a resolução de MUAPs superpostos pode vir a se tornar viável clinicamente, estudos envolvendo as vantagens da resolução de MUAPs superpostos estão atualmente em curso. Por outro lado, em relação aos sistemas usados para aplicações mais envolvidas com pesquisa, podem ser sugeridos desenvolvimentos adicionais que teriam um impacto imediato no uso destes sistemas. Desses sistemas se requerem informação mais detalhada e como tal devem solucionar MUAPs sobrepostos e determinar com precisão os padrões de disparo incluindo os tempos precisos de recrutamento e decrutamento. Todos os sistemas atuais aplicados com propósitos de pesquisa exigem algum grau de interação do operador para selecionar limiares de detecção e associação, confirmar resolução de superposição, determinar a validade dos padrões de disparo ou avaliar a qualidade da decomposição. Qualquer melhoria que reduza a quantidade de interação do operador e conseqüentemente o tempo requerido para decompor e analisar um sinal EMG detectado seria muito importante.

De modo geral, os parâmetros obtidos da decomposição provêem informação quantitativa que pode ser usada para ajudar no diagnóstico clínico e tratamento de desordens neuromusculares. Estes parâmetros podem ser

arranjados através de análise estatística usando testes univariados e/ou multivariados (Pfeiffer & Kunze, 1995, Pattichis & Elia, 1999). Além disto, este conjunto expandido de parâmetros pode ser usado para estudar a fisiologia básica da UM em sistemas neuromusculares, tanto normais quanto patológicos ou os efeitos do envelhecimento e fadiga. Resultados obtidos do uso de sistemas de decomposição de sinais EMG até este ponto são apenas preliminares. Não se tem ainda disponível um conjunto amplo de dados que possam ser usados sistematicamente para estudar mudanças em sistemas neuromusculares. Mais dados precisam ser coletados e analisados. A utilidade potencial dos vários parâmetros descritos deve ser ainda mais investigada.

CAPÍTULO 5

AQUISIÇÃO DE DADOS E GERAÇÃO DOS CONJUNTOS DE TREINAMENTO

5.1 Protocolo para aquisição dos sinais EMG

Os sinais EMG foram preliminarmente coletados dos músculos bíceps braquial de três grupos distintos: sujeitos normais (NOR); pacientes sofrendo com patologias do neurônio motor (NMO); e miopatias (MIO). Sendo que o grupo normal (NOR) foi constituído por 11 voluntários saudáveis (6 homens e 5 mulheres) com idade variando entre 22 e 40 anos. O grupo de pacientes sofrendo de disfunções do neurônio motor (NMO), foi constituído por 13 voluntários (8 homens e 5 mulheres) com idades variando entre 5 e 20 anos, a maioria com diagnóstico de paralisia cerebral. O grupo de pacientes sofrendo de miopatias (MIO) foi constituído por 8 voluntários (6 homens e 2 mulheres), sendo que os homens, com idades variando de 5 a 15 anos, sofrendo de distrofia muscular progressiva tipo Duchenne, e as 2 mulheres com idades de 18 e 24 anos respectivamente sofrendo de distrofia muscular do tipo cinturas. Os critérios de diagnósticos foram baseados em opinião clínica, dados bioquímicos e biópsia muscular. Dentro do grupo normal somente foram incluídos sujeitos sem nenhum histórico ou sinais de desordens neuromusculares. Ademais, o músculo bíceps braquial foi escolhido porque é um músculo proximal da base do ombro, que normalmente é afetado em estágios iniciais em ambos grupos patológicos, NMO e MIO. Também, o fato

de ser facilmente acessível o torna atrativo para estudos, além de ser amplamente reportado pela literatura correlata.

Os sujeitos foram posicionados sentados em posição confortável com ambos pés firmemente apoiados no chão, tendo o braço dominante repousado sobre uma superfície plana e seu antebraço conectado em um dispositivo mecânico, conforme Figura 5.1. O dispositivo foi desenhado para ajustar o ângulo do cotovelo em torno de 90°, com uma correia de pulso conectada a um dinamômetro de mola. Para aquisição do sinal EMG foram usados eletrodos ativos diferenciais de superfície (Delsys modelo. DE 2.1 com distância intereletródica de 10 mm, e ganho 10), com suportes auto-adesivos para minimizar a geração de artefatos de movimento no sinal (Figura 5.2).

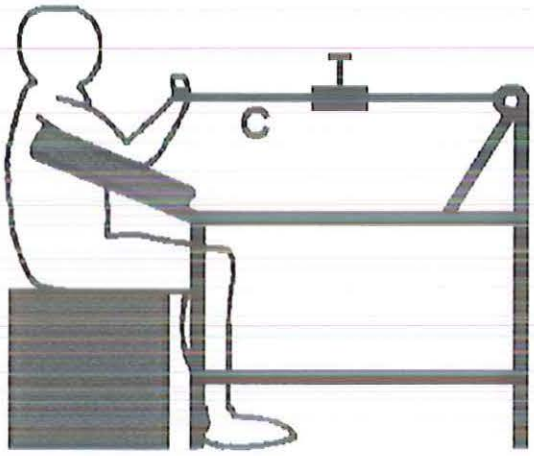

Figura 5.1 – Arranjo usado para coleta dos sinais durante as contrações isométricas. Onde T é um dinamômetro de mola, C é uma cinta ajustável presa a uma correia no punho do sujeito.

Figura 5.2 - Eletrodo ativo diferencial com suporte auto-adesivo (extraído de http://www.delsys.com).

O local de posicionamento do eletrodo sobre o músculo era inicialmente limpo com algodão embebido em álcool isopropílico, para eliminar possíveis gorduras e reduzir a resistência da pele. Os eletrodos foram posicionados na porção medial da barriga do músculo (cabeça curta), no ponto médio entre a zona de inervação (ponto motor) e a inserção tendinosa, conforme ilustra a Figura 5.3. As razões para essa escolha são descritas a seguir. Próximo da inserção tendinosa as fibras musculares se tornam mais estreitas e menos numerosas, reduzindo a amplitude do sinal EMG. Também nesta região a dimensão física do músculo é consideravelmente reduzida tornando difícil localizar o elétrodo corretamente, fazendo a detecção do sinal suscetível a sobreposições devido à proximidade de músculos agonistas, e pela mesma razão deve-se evitar as bordas externas do músculo. Durante os últimos 50 anos difundiu-se o conceito errôneo de que para se detectar um sinal EMG superficial o eletrodo deveria ser localizado num ponto motor do músculo. O ponto motor é aquele ponto no músculo onde a introdução de uma corrente elétrica mínima causa uma contração perceptível das fibras musculares superficiais. Este ponto normalmente, mas nem sempre, corresponde àquela parte da zona de inervação no músculo com maior densidade neural, dependendo da anisotropia do músculo nesta região. Presumivelmente, os pontos motores foram usados como marcos porque eles eram identificáveis e, portanto um marco anatômico fixo. Infelizmente do ponto de vista da estabilidade do sinal, *ponto motor provê o pior local* para detectar um sinal EMG. Na região de um ponto de motor, os potenciais de ação viajam nos dois sentidos ao longo das fibras musculares, assim as fases positivas e negativas dos potenciais de ação (detectadas pela configuração diferencial) serão somadas e/ou subtraídas com a menor diferença de fase causando no sinal EMG resultante componentes de freqüência mais altos. No domínio do tempo, o sinal aparece mais denteado e com picos mais agudos. A perda de estabilidade decorre do fato de um deslocamento mínimo (0.1 mm) afetar de forma imprevisível as características de freqüência do sinal.

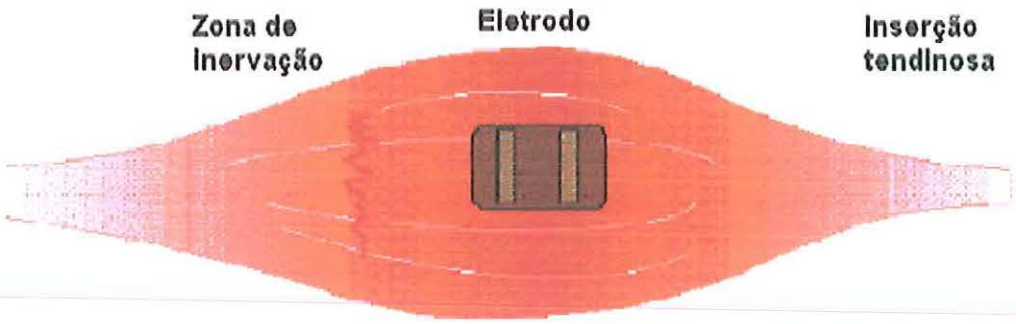

Figura 5.3 - A localização preferida é entre o ponto motor e a inserção tendinosa, com as superfícies de detecção arranjadas tal que interceptem o maior número possível de fibras. (adaptado de http://www.delsys.com).

Os sinais EMG do músculo bíceps braquial do braço dominante dos sujeitos foram estudados em três situações diferentes. No primeiro experimento, o sinal era adquirido com o músculo em repouso, e o sujeito podia se familiarizar com o equipamento, visualizando na tela do monitor o valor RMS do sinal que estava sendo adquirido na forma de um gráfico de barras. Nesta etapa também eram as feitas correções no posicionamento do eletrodo e corrigidos possíveis problemas de mau contato no eletrodo de referência. No segundo experimento, o sujeito era instruído a produzir a contração voluntária máxima (CVM), na melhor de três tentativas, e visualizar seu valor RMS no monitor. O maior valor produzido nas três tentativas era armazenado e referenciado como 100% da CVM. Cada contração durava no máximo 4 segundos, com 5 minutos de intervalo para evitar o fenômeno da fadiga. Nesta etapa o ganho do amplificador podia ser ajustado, a fim de se evitar que sinais EMG de amplitude elevada viessem a saturar o conversor A/D. No terceiro experimento, o sujeito era então instruído a realizar uma contração sustentada de baixo nível (de 5 a 10% da CVM) em três tentativas, cada tentativa durava no máximo 20 segundos, com intervalos de 5 minutos. Nesta etapa, a realimentação visual do sinal no monitor era decisiva para auxiliar o sujeito a manter uma contração dentro do percentual da CVM requerido, da forma mais isométrica possível. O sinal com a melhor relação

sinal-ruído obtido nas três tentativas foi armazenado para processamento posterior.

Os sinais EMG foram adquiridos a uma taxa de 10 kHz e filtrados em banda de 20 Hz a 2 kHz, por um módulo de aquisição multicanal para sinais EMG modelo MYOSYSTEM 2000 fabricado por NORAXON USA Inc., e digitalizados por um conversor A/D de aproximação sucessiva de 12 bits, conectado à um computador pessoal. O módulo de aquisição teve o ganho ajustado para 100, de modo que combinado ao ganho 10 do eletrodo ativo, permiti-se um ganho total 1000 sobre o sinal EMG captado. O software (Myoresearch 5.0), fornecido pelo fabricante do equipamento, foi utilizado para armazenar os sinais formando um banco de dados dos pacientes, além de facilitar o trabalho de aquisição disponibilizando a função "*biofeedback*", que mostra na tela um "*bargraph*" com o valor RMS do sinal "*on line*" (amostrado em janelas de 60 ms), o qual conforme foi dito, facilitou ao sujeito via realimentação visual manter o nível de contração isométrica requerido durante os experimentos.

Em relação à taxa de amostragem, pelo fato de estarmos comparando formas de componentes do sinal, para obter-se suficiente resolução e evitarmos o uso de técnicas de interpolação, uma taxa de cinco vezes a freqüência máxima do sinal é um compromisso entre superamostragem extrema e taxa mínima de Nyquist. Então limitando o sinal em banda até 2 khz teremos um bom compromisso. Além do que a filtragem em banda e a aplicação de diferenciadores passa-baixas encurtam a duração dos MUAPs, reduzindo a sobreposição temporal e portanto a quantidade de ondas superpostas.

5.2 Geração dos conjuntos de treinamento

Focamos nossa discussão na decomposição de EMGs superficiais de canal único digitalizados e amostrados a uma taxa de 10 kHz. Com um período total de 20 segundos (ou 10 segundos) de sinal EMG sendo gravado sob contração isométrica à um nível baixo de contração (5 à 10 % da CVM). Preliminarmente, fizemos testes apenas com sinais EMGs do grupo NOR, o objetivo foi desenvolver um protótipo para decomposição dos EMGs de superfície. Em seguida o protótipo desenvolvido será usado nos testes com os grupos MIO e MNO, para um estudo clínico.

A detecção dos candidatos a MUAP é uma das tarefas mais importantes de um algoritmo para decomposição de EMGs. Um detector que seja capaz de encontrar os verdadeiros candidatos a MUAP e rejeitar os falsos melhoraria consideravelmente a performance da decomposição (Sptizer et al., 1989). O detector consiste de um filtro em série com um detector de picos. O filtro é projetado para acentuar os picos dos MUAPs e suprimir a atividade de fundo. Para acentuar os picos e facilitar a detecção, nós adotamos um tipo de filtro diferencial passa-baixas (DPB) descrito em Usui & Amidor (1982), e introduzimos uma mudança que denominamos de filtro diferencial passa-baixas ponderado senoidal (DPBP). O filtro é definido como:

$$y_k = \sum_{n=1}^{N_S} w(n) \cdot \left(x_{k+n} - x_{k-n} \right) \qquad \textbf{(5.1)}$$

onde $w(n)$ é uma função de janelamento com largura N_s pontos, x_k é a entrada, e y_k é a saída filtrada. A função de janelamento é uma função senoidal definida como:

$$w(n) = sin\left(\frac{n \cdot \pi}{N_S}\right) \qquad 0 \leq n < N_S \tag{5.2}$$

Diferente do filtro DPB simples, o filtro DPBP senoidal é uma soma ponderada de um número grande de diferenças discretas do sinal com diferentes intervalos de tempo. A Figura 5.4 e 5.5 mostra a superioridade do filtro DPBP em relação a um filtro DPB. Esta filtragem encurta a duração dos MUAPs podendo remover informação de baixa freqüência não discriminativa e facilitar a discriminação entre MUAPs de UMs diferentes pela redução da variabilidade das formas dos MUAPs. Reduz também a amplitude de muitos MUAPs de UMs diferentes com formas similares que não tem fibras próximas ao eletrodo. O número de somatórias N_s deve ser suficientemente grande para atuar sobre o raio de influência de um pico, sem no entanto extrapolar seus limites, o que vai depender da gama de variação da duração do MUAP e da taxa de amostragem do sinal EMG. Considerando, que a duração esperada de um MUAP varia de 8.8 ms até 18 ms e a taxa de amostragem é 10 kHz, N_s pode ser ajustado até 40. Valores muito pequenos de N_s aproximam os resultados do filtro DPB, já valores demasiadamente elevados causam distorções no sinal, do ajuste desse parâmetro depende o sucesso na discriminação dos picos e do reconhecimento nas etapas seguintes.

O detector de picos localiza a máxima energia de um segmento de dados em cada janela móvel, e a compara com um limiar pré-ajustado. Se a energia excede o limiar, o candidato é identificado. A forma de onda é então extraída do sinal. Em seguida um processo de alinhamento é realizado, um segmento da forma de onda do MUAP (largura N), com o pico principal alinhado no centro é coletado, como mostra a Figura 5.6. A largura da janela (N) da qual será extraído o pico, depende da taxa de amostragem, devendo ser ajustada em torno da duração média dos MUAPs. Adotamos N igual a 128, que equivale a 12.8 ms na taxa da amostragem usada. Esse valor foi obtido

empiricamente a partir de amostras representativas dos MUAPs detectados, selecionados de modo supervisionado a partir do conjunto de sinais estudados.

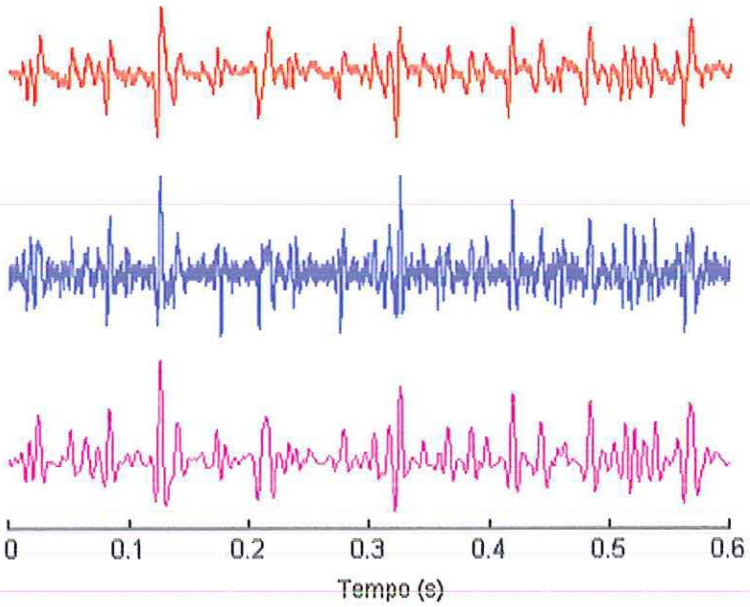

Figura 5.4 - Um sinal EMG puro e suas saídas filtradas. Topo: segmento de um EMG gravado no bíceps braquial sob contração fraca (~10% CVM) por eletrodos de superfície bipolares amostrado à 10 kHz. Meio: o mesmo segmento filtrado usando um simples filtro DPB (*N*=3) Em baixo: o mesmo segmento filtrado usando um filtro DPBP senoidal.

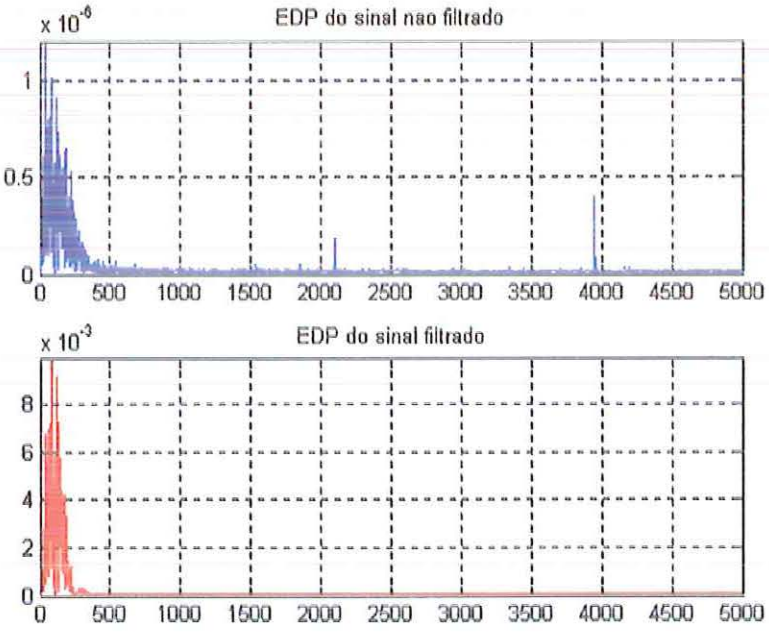

Figura 5.5 – Espectro de potência do sinal puro e do sinal filtrado usando o filtro DPBP senoidal.

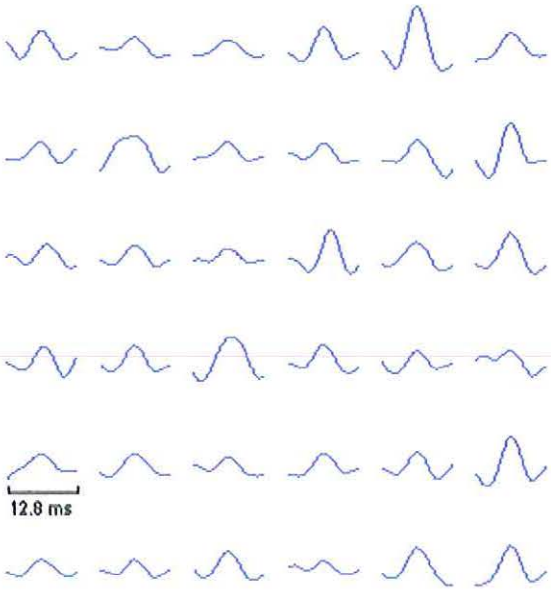

Figura 5.6 – Exemplo da saída do detector de picos (limiar de detecção a 20%). As formas de ondas dos MUAPs candidatos são extraídas de um segmento de EMG (1s de intervalo, adquirido a menos de 10% da CVM), tendo o pico principal alinhado no meio da janela (largura da janela = 12.8 ms).

Quando um MUAP candidato é extraído do sinal, um registro é criado para armazenar a informação do candidato. A posição temporal e a forma de onda são armazenadas no registro. Os segmentos com os MUAPs detectados (P_i) são representados como vetores. Esses vetores são concatenados numa matriz i linhas por N colunas e são chamados *vetores de treinamento*, a matriz é chamada *conjunto de treinamento*, são eles que vão alimentar o algoritmo do mapa de kohonen (SOM) para treinamento. A estrutura completa do conjunto de treinamento é mostrada na Figura 5.7.

Desde que o algoritmo SOM é baseado na distância euclidiana, a escala das variáveis é muito importante na forma que o mapa irá tomar. Se a faixa de valores de alguma variável é muito maior que a das outras, ela irá provavelmente dominar a organização do mapa completamente. Por essa razão, os componentes de dados são usualmente normalizados, por exemplo, de tal modo que cada componente tenha variância unitária. Esse processo é

feito automaticamente pelo algoritmo, então para a informação de norma não se perder, mais um dado deve ser armazenado para representar a norma da forma de onda, possibilitando sua recuperação após o processo de classificação.

O processo de classificação automática pode ser pensado como um método que adiciona uma coluna à matriz de dados, onde esta coluna é exatamente a classe do padrão, no nosso caso um conjunto de MUAPs semelhantes que vão formar um MUAPT.

$$\begin{bmatrix} P_1 \\ P_2 \\ \vdots \\ P_i \end{bmatrix} = \begin{bmatrix} x_{1,1} & x_{1,2} & \cdots & x_{1,N} \\ x_{2,1} & x_{2,2} & \cdots & x_{2,N} \\ \vdots & \vdots & \cdots & \vdots \\ x_{i,1} & x_{i,2} & \cdots & x_{i,N} \end{bmatrix}$$

MUAPs candidatos

Ocorrência temporal

$$N = \begin{bmatrix} N_{P1} & N_{P2} & \cdots & N_{Pi} \end{bmatrix}^T$$

Informação de norma

Figura 5.7 - Estrutura final do conjunto de treinamento. Cada linha da matriz representa um MUAP candidato de comprimento *N*, com o pico principal alinhado no meio do segmento. A ocorrência temporal do pico principal de cada MUAP é gravada num vetor unidimensional indexado ao índice do MUAP candidato. A informação de norma é gravada num vetor unidimensional separado.

Os algoritmos usados neste capítulo foram implementados através do software Matlab 6.1.

CAPÍTULO 6

MAPAS AUTO-ORGANIZÁVEIS DE KOHONEN PARA CLASSIFICAÇÃO DE MUAPS

Este capítulo descreve a ferramenta básica que iremos explorar para detecção dos agrupamentos de MUAPs, o SOM (*Self-Organizing Maps*). Os mapas (de atributos) auto-organizáveis foram inicialmente desenvolvidos pelo Prof. Teuvo Kohonen (1982a, b) e constituem um dos principais paradigmas na área de redes neurais artificiais. O SOM foi inspirado no modo pelo qual informações sensoriais são mapeadas no córtex cerebral. SOM é um algoritmo não supervisionado que aproxima a densidade de probabilidade dos estímulos de entrada ao mesmo tempo em que reduz a dimensionalidade, tentando preservar ao máximo as relações topológicas entre os dados.

O objetivo deste capítulo é fornecer fundamentos para estudo e aplicação do SOM nos problemas de classificação automática de MUAPs. O SOM é uma ferramenta básica junto a qual os algoritmos desenvolvidos neste trabalho são aplicados. Descrevemos a arquitetura e o processo de treinamento, analisando o funcionamento, bem como o processo de classificação e extração de características. Também se discute uma série de limitações deste modelo e algumas heurísticas para tentar resolvê-las. Neste capítulo, restringimo-nos a aspectos mais fundamentais, sendo que uma vasta literatura está disponível, sendo Kohonen (1997a) a principal referência na atualidade.

6.1 Introdução

A tarefa de classificação do SOM é gerar agrupamentos (*clusters*) que tenham formas de onda similares. Os clusters, após um processo de refinamento, são usados para formar os trens de MUAPs (MUAPTs). A classificação no SOM é realizada em duas fases. Durante a primeira fase, O SOM aprende características e morfologias de classes dos exemplos de entrada, e constrói uma representação interna dos padrões aprendidos. Na segunda fase, o SOM identifica as classes de cada exemplo de entrada.

Vários tipos de redes neurais podem ser adotadas para processar EMGs, o SOM é uma boa escolha. Antes de tudo, uma rede neural com aprendizagem supervisionada não é adequada, desde que a aprendizagem supervisionada requer um vetor alvo conhecido para cada padrão de treinamento, e o sinal EMG não pode prover tais vetores alvos. Em essência, nenhuma informação prévia acerca do significado do sinal EMG está disponível, sendo assim, o ajuste de pesos sinápticos via treinamento não-supervisionado deve recorrer apenas aos dados de entrada, assumidos como amostras independentes de uma distribuição de probabilidade desconhecida. Em contraposição ao treinamento supervisionado e ao treinamento por reforço, não há no SOM nenhuma saída explícita ou avaliação externa da saída produzida para cada dado de entrada. No SOM nenhuma informação sobre a classe do estímulo apresentado é usada no processo de ajuste dos pesos sinápticos, a extração de regularidades estatísticas (ou então irregularidades) se dá diretamente sobre os dados de entrada. Como vemos o SOM é uma boa escolha, existem outras arquiteturas de redes auto-organizáveis que poderiam ser testadas, por exemplo, o modelo ART, *Adaptative Ressonance Theory,* (Carpenter & Grossberg, 1987), no entanto a motivação biológica aliada à simplicidade do código e da visualização das relações entre os dados foi fundamental em nossa opção pelo SOM.

EESC-USP Biblioteca Campus de S. Carlos

A seguir, descrevemos brevemente a idéia do aprendizado competitivo, e mais adiante sua implementação no SOM. Em seguida descrevemos um processo de geração dos conjuntos de protótipos que representará os agrupamentos no espaço p-dimensional, baseando-se na segmentação da imagem do gradiente (*U-matrix*) de todos os componentes de um mapa treinado.

6.2 Aprendizado Competitivo

O objetivo básico do aprendizado competitivo é fazer com que neurônios se especializem em estímulos apresentados de forma não supervisionada. Isto é, nenhuma informação sobre a classe do estímulo apresentado é usada no processo de ajuste dos pesos sinápticos. Todos os neurônios recebem o mesmo conjunto de entradas e competem, através de uma dinâmica que usa conexões laterais, com todos os outros neurônios. Estas conexões laterais podem ser positivas (no caso da auto-realimentação) ou inibitórias (negativas).

O princípio básico de aprendizado competitivo é quantização vetorial (QV), que de uma forma ou de outra, aproxima a função densidade de probabilidade do sinal de entrada por um conjunto finito de vetores de referência, ou *codebooks*. Várias aplicações de QV estão disponíveis nas áreas de telecomunicações e processamento de sinais e imagens.

Existem três elementos básicos em regras de aprendizado competitivo:

1. O conjunto de neurônios com mesma função de ativação, apenas diferindo inicialmente pela aleatoriedade da distribuição dos pesos sinápticos, o que os farão responder diferentemente para um dado conjunto de padrões;
2. Os vetores de pesos que conectam neurônios entre as camadas de entrada e de saída são limitados, por exemplo, $\| \boldsymbol{m} \| = 1$;

3. Um mecanismo que permita aos neurônios competir pelo direito de responder a um dado subconjunto de entradas. No final do processo de competição, apenas um neurônio estará ativo, regra *winner-takes-all*.

Tais condições são em muitos casos estendidas ou mesmo desconsideradas. Por exemplo, existem regras onde podemos considerar mais de um neurônio vencedor para um dado padrão, ou mesmo não necessitar normalizar os pesos como descrito pela condição 2.

Considere a rede apresentada na Figura 6.1. Suponha que um vetor $\boldsymbol{x}$, normalizado ($\|\boldsymbol{x}\| = 1$), é apresentado à camada de entrada da rede. Cada neurônio O_i, $i = 1, 2, \ldots k$, da camada de saída irá computar um valor de ativação. O neurônio vencedor, c, é o neurônio que apresenta a ativação máxima, i.e., maior similaridade com o padrão apresentado. As conexões laterais podem ser utilizadas em um processo dinâmico de competição (Kohonen, 1997), de forma a inibir os outros neurônios. No final do processo apenas um neurônio, c, permanecerá ativo. Existem várias formas de fazer isto, sendo a mais simples pegar o neurônio vencedor e saturá-lo, por exemplo, em 1, enquanto todos os outros são desativados, i.e., suas ativações são anuladas para aquele padrão.

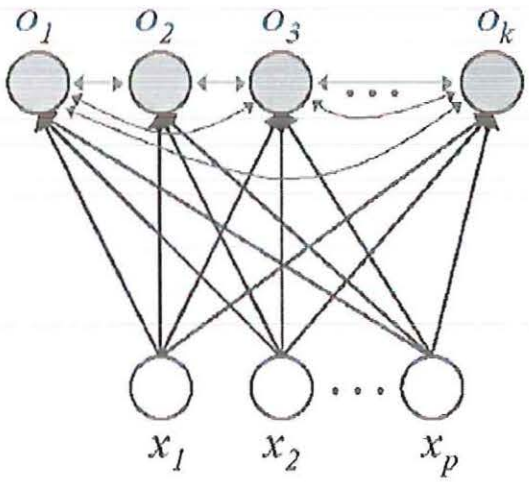

Figura 6.1 – Esquema simplificado de uma rede neural competitiva, (Kohonen, 1997).

Apesar de algumas semelhanças com o método *k-means*, no caso do *k-means* a cada iteração os vetores de média são calculados de acordo com os membros provisórios de cada agrupamento. No caso do aprendizado competitivo, o ajuste é restrito ao neurônio vencedor a cada apresentação de um padrão, sendo este neurônio vencedor o neurônio que possui o conjunto de pesos mais semelhante ao padrão apresentado. Dado um critério de distância, ou dissimilaridade, entre x e m_i, $d(x, m_i)$, o vencedor, c, é identificado de forma que:

$$d(x, m_c) = \min_i \{d(x, m_i)\} \tag{6.1}$$

A adaptação ocorre apenas aos pesos sinápticos do neurônio vencedor, c:

$$\Delta m_c(t+1) = \alpha(t).[x(t) - m_c(t)] \tag{6.2}$$

Para todos os outros neurônios, $i = 1,..., k$, $i \neq c$, $\Delta m_i(t+1) = 0$. A taxa de aprendizado, $\alpha(t)$ pode ser uma função (ou seqüência de valores) decrescente, monotônica, limitada em $0 < \alpha(t) < 1$. O efeito desta regra é o deslocamento dos pesos do neurônio vencedor na direção do padrão x (veja a Figura 6.2).

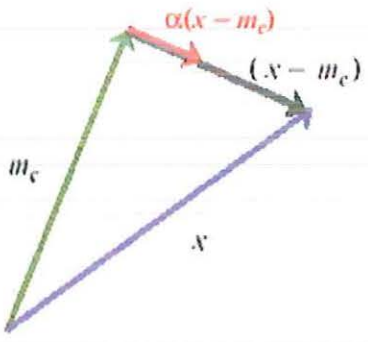

Figura 6.2 – Esquema de atualização dos pesos em uma rede neural competitiva.

6.3 Estrutura básica do SOM

Apesar de ter sido desenvolvido inicialmente para tentar modelar áreas sensoriais do córtex, e das iterações laterais entre os neurônios em tais estruturas, o SOM é um algoritmo extremamente simplificado e apenas superficialmente podemos compará-lo a uma estrutura biológica real. Porém, o nosso objetivo neste trabalho é a aplicação do mapeamento não linear que o algoritmo faz junto aos dados de entrada, de forma não supervisionada, e não o estudo de características reais de áreas do córtex.

A visão moderna do SOM é de uma ferramenta de software para a visualização de dados. Geralmente dados de aplicações reais são multidimensionais o que torna difícil a visualização das relações entre os dados. O SOM implementa uma projeção não-linear de um espaço de dados sensoriais ou de atributos $\Re^p$, geralmente de dimensionalidade elevada ($p >> 2$), em um conjunto discreto de neurônios, geralmente dispostos na configuração de um vetor ou uma matriz. Relações estatísticas complexas e não-lineares entre os dados são convertidas em relações geométricas simples sobre um '*display*' de menor dimensionalidade. Apesar de ter sido relacionado a componentes principais (CP), existem diferenças fundamentais entre estes dois métodos, como por exemplo, o espaço discreto de saída do SOM, enquanto que em CP o espaço é contínuo. Além disto, componentes principais são obtidos por combinações lineares das variáveis, enquanto que o SOM é obtido matematicamente por regressão recursiva e não paramétrica (Kohonen, 1997a), e ao levar em conta a topologia da rede resulta em uma projeção não linear da densidade de probabilidade $p(x)$ dos sinais de entrada sobre a grade de neurônios.

Apesar de alguns autores descreverem como antagônicos, os dois objetivos principais do SOM são reduzir a dimensionalidade dos dados ao mesmo tempo em que se tenta preservar as relações métricas e topológicas do

espaço de entrada. A dimensionalidade do mapa é dada pelas relações de vizinhança entre os neurônios. Uma outra característica obtida de um SOM treinado é a aproximação da função densidade de probabilidade dos dados, o que também será explorado neste trabalho, de uma forma ordenada. Devido à preservação das relações topológicas, informações semelhantes são mapeadas em neurônios próximos, eventualmente no mesmo neurônio, o que caracterizará a quantização ou agrupamento do espaço de entrada. As relações de vizinhança entre os neurônios nos permitirão a união posterior dos neurônios que respondem a estímulos semelhantes em conjuntos de neurônios. Esta é uma diferença básica frente a outros modelos de redes neurais competitivas, como a ART (Carpenter & Grossberg, 1987), no qual pode ocorrer de pontos vizinhos no espaço de entrada serem mapeados em neurônios distantes na camada de saída da rede.

Um mapa auto-organizável consiste de duas camadas de neurônios: a camada de entrada, I, e a camada de saída (ou de Kohonen), U. As entradas da rede são vetores no espaço p-dimensional, geralmente no espaço $\Re^p$. Cada neurônio i da camada de Kohonen possui um vetor também no espaço $\Re^p$ associado, $\boldsymbol{m}_i = [m_{i1}, m_{i2},..., m_{ip}]^T$. Os neurônios na camada Kohonen são conectados aos neurônios adjacentes por uma relação de vizinhança que descreve a estrutura do mapa, como descrito anteriormente. No caso bidimensional podemos ter vizinhança tipo 4-conectados (mapas retangulares) ou 6-conectados (mapas hexagonais). A escolha da topologia, assim como o tamanho do mapa, N x M, dependem da aplicação. Geralmente usam-se SOMs retangulares por razões de simplicidade. A Figura 6.3 ilustra um SOM para o caso em que $p = 3$, e a camada U possui tamanho $7x10$.

Dois tipos de distâncias existem no SOM: a primeira é a distância entre os índices da matriz ou vetor que forma o reticulado (*grade*) dos neurônios, *(k, c),* onde k e c representam as coordenadas dos neurônios na

grade. Esta distância é bastante usada durante o treinamento, no qual a atualização dos pesos sinápticos será efetuada, em um dado passo t, para neurônios dentro de um raio (decrescente com t) do neurônio vencedor (ver Figura 6.4). A outra distância refere-se à distância no espaço de pesos, i.e., a distância entre um padrão $\boldsymbol{x}$ e um neurônio $\boldsymbol{m}_i$. Este tipo de distância depende da métrica a ser usada no problema. Em geral usam-se para tal fim a distância Euclidiana ou a de Hamming. O mesmo critério de distância usado para encontrar o neurônio vencedor pode ser usado, como veremos mais adiante, para calcular distâncias entre neurônios, o que nos permitirá fazer a análise de um SOM treinado. A Figura 6.5 apresenta um modo simples e funcional de visualizar o SOM. Cada neurônio possui um *'endereço'* na grade e todos recebem os mesmos sinais provenientes da entrada $\boldsymbol{x} = \{x_1, x_2, x_3\}$. Pode-se ver, associado a cada neurônio, um vetor na mesma dimensão da entrada (no caso *3*). Esta figura será de bom uso quando discutirmos métodos de visualização de um SOM treinado.

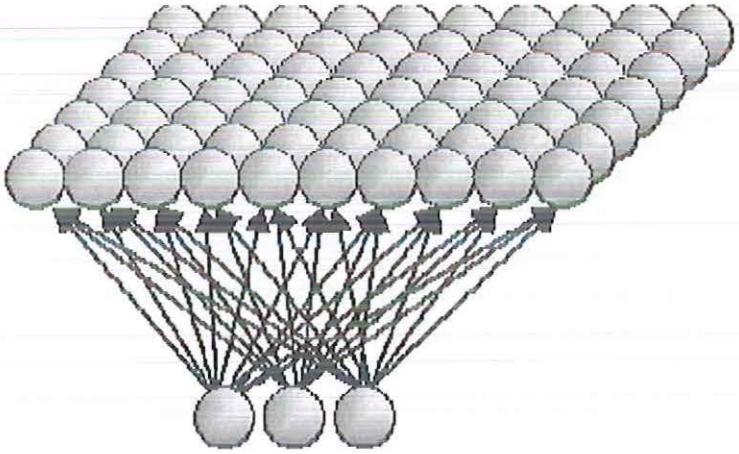

Figura 6.3 – SOM com tamanho 7x10 e dimensionalidade de entrada, $p = 3$, (Kohonen, 1997).

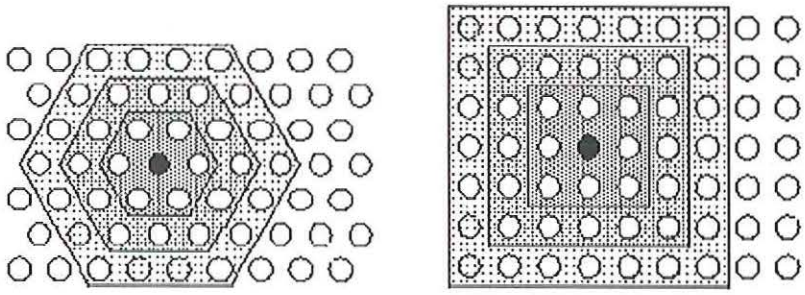

Figura 6.4 – Duas configurações de grade e níveis de vizinhança do neurônio vencedor aos neurônios circunvizinhos, (Kohonen, 1997).

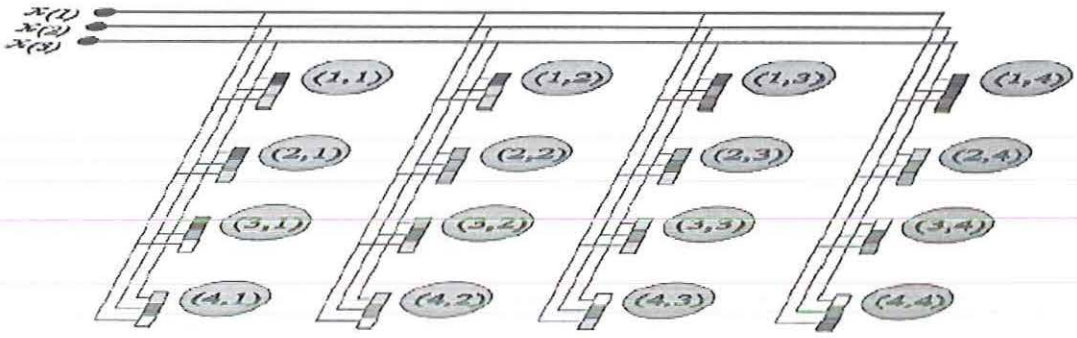

Figura 6.5 – Som com tamanho 4x4 e dimensionalidade de entrada, p =3.

6.4 Treinamento do SOM

6.4.1 Algoritmo convencional

Talvez uma das razões do sucesso do SOM seja a simplicidade do algoritmo de treinamento. Geralmente, o processo de treinamento do SOM consiste de apenas quatro etapas, além da inicialização:

1. Inicialização da rede. Pode-se usar estratégias descritas na seção 6.4.3 para gerar os vetores de pesos iniciais $\boldsymbol{m}_i$, $i = 1, \ldots, n$, onde n é o número de neurônios;

2. Um padrão de entrada $\boldsymbol{x}_k = (\xi_1, \xi_2, \cdots, \xi_p)$, $\boldsymbol{x}_k \in \Re^p$, é selecionado aleatoriamente de todo conjunto de padrões;

3. Uma função de ativação é usada para calcular o estado de cada neurônio *i* em relação ao padrão x_k. No caso da distância Euclidiana, temos a equação abaixo;

$$d(m_i, x_k) = \sqrt{\sum_{j=1}^{p} \left[x_{kj}(t) - m_{ij}(t)\right]^2} \qquad \textbf{(6.3)}$$

4. O neurônio vencedor, *c*, é escolhido de acordo com a equação;

$$\|x - m_c\| = \min_i \{\|x - m_i\|\} \qquad \textbf{(6.4)}$$

onde $\|\cdot\|$ denota a distância utilizada, no nosso caso a Euclidiana.

5. Os pesos sinápticos do neurônio vencedor, *c*, como também os pesos dos neurônios que estão dentro da vizinhança de *c* são atualizados através da seguinte equação;

$$m_i(t+1) = m_i(t) + h_{ci}(t).[x(t) - m_i(t)] \qquad \textbf{(6.5)}$$

Onde *t* é a iteração ou passo dentro de uma época, *x(t)* é o padrão de treinamento, geralmente escolhido de forma aleatória do conjunto de dados no passo *t*, e $h_{ci}(t)$ é o núcleo de vizinhança ao redor do neurônio vencedor *c* no passo *t*. Este último termo é uma função decrescente com o tempo e com a distância do neurônio *i* ao neurônio vencedor *c*, e geralmente é formado por dois componentes: a taxa de aprendizado $\alpha(t)$ e a função de vizinhança $h(d, t)$:

$$h_{ci}(t) = \alpha(t) \cdot h\left(\|r_c - r_i\|, t\right) \qquad \textbf{(6.6)}$$

Onde r_i é a posição do neurônio *i* na camada de Kohonen.

O processo definido pelos passos 2-5 é repetido iterativamente, o que leva a um mapeamento gradual de preservação da topologia dos sinais de entrada à medida que o algoritmo de treinamento converge.

Ao final do treinamento espera-se que o mapa esteja topologicamente ordenado. Basicamente isto significa que n_i padrões que estejam próximos no espaço p-dimensional de atributos devem ser mapeados em neurônios que estejam próximos no espaço da grade, geralmente no mesmo neurônio ou em neurônios vizinhos. Porém o inverso não é verdadeiro: dois neurônios vizinhos no espaço da grade podem estar bastante distantes no espaço de atributos. Esta informação será de grande valia quando formos segmentar automaticamente o mapa.

6.4.2 Comentários sobre o processo de treinamento do SOM

Treinamento (ou estimação de parâmetros) em redes neurais, ou outros sistemas estatísticos, envolve geralmente a minimização (ou maximização) de um funcional no qual os parâmetros a serem estimados são grandezas independentes. No caso de treinamento supervisionado, além da entrada $x(t)$ a ser apresentada à rede neural, apresentamos a correspondente saída desejada τ. A minimização dos parâmetros geralmente usa uma função derivada de gradiente descendente no espaço de pesos de uma função erro entre o conjunto de respostas providas pela rede $\underline{\psi}$ e o conjunto de saídas desejadas $\underline{\tau}$. O critério de término pode ser um valor pré-especificado para o funcional, um número máximo de iterações, a estabilização (no tempo) dos parâmetros, ou uma combinação destes fatores.

No caso do SOM, dado o conjunto de entradas $\Xi = x_k$, $1 \leq k \leq n$, originários de um espaço $\Re^p$, em cada passo uma entrada $x(t) \in \Xi$ é selecionada, geralmente de forma aleatória, para a apresentação ao SOM,

garantindo uma uniformidade de apresentações de todos os $\boldsymbol{x}_k \in \Xi$. Define-se uma época como a apresentação completa do conjunto de padrões, Ξ, à rede neural.

Um dos principais problemas no treinamento do SOM é a ausência de um funcional ou um critério de otimização. A ausência das informações referentes à saída desejada para cada padrão de entrada no treinamento faz com que a alternativa de adaptação dos pesos seja feita de forma não supervisionada, i.e., através de um processo competitivo. O objetivo é *"sintonizar"* os neurônios às entradas, i.e., que um neurônio vencedor *best match unit* (BMU) de um determinado padrão de entrada responda mais intensamente àquele padrão na próxima época. O grau de adaptação, em uma iteração t, depende da taxa de aprendizado $\alpha(t)$, da função de vizinhança $h(d, t)$ e da distância entre o neurônio i, representado pelo seu vetor sináptico $\boldsymbol{m}_i$, e o vetor $\boldsymbol{x}(t)$.

A etapa do treinamento do SOM que mais consome tempo é encontrar o neurônio vencedor. Geralmente usa-se busca seqüencial, o que torna o processo extremamente custoso quando o número de neurônios é elevado.

À medida que o treinamento prossegue e os padrões são apresentados à rede, a taxa de aprendizado $\alpha(t)$ decresce gradualmente a um valor pré-especificado, geralmente próximo a zero, de acordo com uma dada função de decaimento. Isto garante o término do processo de aprendizado em um tempo finito. Geralmente usam-se funções monotônicas decrescentes na faixa de valores [0, 1]. Um exemplo para $\alpha(t)$ poderia ser:

$$\alpha(t) = \alpha(0) \cdot e^{-\left(\frac{t}{\lambda}\right)} \tag{6.7}$$

onde $\alpha(0) < 1$, é a taxa de aprendizado inicial e λ é um parâmetro responsável pela taxa de redução desejada.

De forma similar, a vizinhança ao redor do neurônio vencedor, $h_{ci}(t)$, equação (6.6), decresce com o tempo a uma taxa também previamente especificada. Esta vizinhança é considerada o principal agente da auto-organização no SOM (Kohonen, 1982a,b) responsável pela preservação das relações topológicas. Esta propriedade faz com que um estímulo que excita um dado neurônio η no SOM influencie, de uma certa forma, outros neurônios que estão na vizinhança de η. A influência pode ser positiva ou negativa, o que podemos denominar, respectivamente, de sinapses laterais excitatórias ou inibitórias. Esta possibilidade de adaptação conjunta de neurônios de um centro de ativação diferencia o SOM de outras redes competitivas que utilizam o princípio *Winner Takes All* (WTA), como por exemplo, a *Adaptive Resonance Theory* (Carpenter e Grossberg, 1987), que só atualizam os pesos do vencedor. Pode-se definir uma região de ativação circular, ou retangular, (veja Figura 6.4) como um conjunto de neurônios $N_c(t)$ em uma região do mapa centrado no vencedor, c. No início do treinamento $N_c(t)$ compreende grande parte do SOM e à medida que o aprendizado prossegue $N_c(t)$ encolhe até que apenas o neurônio vencedor seja atualizado. Por razões de simplicidade, geralmente atualiza-se apenas os pesos dos neurônios dentro da área excitatória, i.e., $h_{ci}(t) = 0$ para neurônios $\boldsymbol{m}_i \notin N_c(t)$ (ver equações 6.5-6.6).

Uma vez encontrado o BMU, o padrão $\boldsymbol{x}$ é mapeado para este neurônio. Os pesos sinápticos de BMU, assim como os pesos dos neurônios dentro da vizinhança de BMU, são deslocados na direção do padrão $\boldsymbol{x}$, de acordo com a equação 6.5. A magnitude do deslocamento é influenciada pela taxa de aprendizado $\alpha(t)$ e pela função de vizinhança $h(d, t)$. O BMU possui o vetor de pesos sinápticos com maior similaridade ao estímulo apresentado.

Geralmente usa-se distância Euclidiana que equivale ao produto interno quando os padrões e os pesos são normalizados em $\|\cdot\| = 1$. Apesar de não obrigatória, grande parte das aplicações na literatura normalizam os dados antes de apresentarem ao SOM, limitando o espaço de entrada a uma hiperesfera p-dimensional de raio 1. A norma Euclidiana de um vetor $\boldsymbol{x} = (x_1, x_2, \ldots, x_p)^T$, pode ser definida como:

$$norma = \sqrt{\sum_{k=1}^{p} x_k^2} \tag{6.8}$$

e os padrões de entrada podem ser normalizados mudando seus componentes para:

$$x_k^{'} = x_k / norma \tag{6.9}$$

A função de ativação baseada no produto interno é descrita na equação (6.10). Todos os padrões de entrada podem ser normalizados antes da apresentação ao SOM.

$$f_i(t) = x^T(t) \cdot m_i(t) = \sum_{k=1}^{p} x_k(t) \cdot m_{ik}(t) \tag{6.10}$$

No caso de distância Euclidiana o BMU foi descrito como o neurônio, c, com menor distância equação (6.4). Como a equação (6.10) define uma função de similaridade entre dois vetores, o BMU será definido como o neurônio mais similar ao estímulo $x(t)$, o que levaria a equação (6.4) a ser escrita como:

$$\left\| x^T \cdot m_c \right\| = \max_i \left\{ \left\| x^T \cdot m_i \right\| \right\} \tag{6.11}$$

A equação (6.4) deve ser rescrita na forma da equação (6.11) sempre que os pesos sinápticos mantenham norma 1. Isto pode ser feito re-normalizando os pesos de todos os neurônios que devam ser atualizados (i.e., os neurônios vencedores e os que estejam dentro da respectiva vizinhança) para um dado instante de tempo *t*.

Quando os padrões e os pesos sinápticos estão normalizados, e usamos como função de ativação a distância Euclidiana, equação (5.8), pode-se provar que devido à expansão de (5.8) como apresentada na equação (6.12), buscar a menor distância entre o padrão $\boldsymbol{x}$ e os neurônios $\boldsymbol{m}_i$, i = 1, 2, ..., equivale a encontrar o máximo valor para $\boldsymbol{m}_i^T \cdot \boldsymbol{x}$.

$$\|x - m_i\| = \left(x^T \cdot x - 2 \cdot m_i^T \cdot x - 1\right)^{1/2} \tag{6.12}$$

6.4.3 Escolha dos parâmetros de treinamento

A escolha correta dos parâmetros do treinamento não é uma tarefa trivial. Várias heurísticas foram propostas, muitas das quais específicas para determinados tipos de problemas. O resultado final do treinamento, mesmo com parâmetros iguais, geralmente é diferente. Isto ocorre devido à basicamente dois fatores aleatórios, como a inicialização dos pesos e a seqüência de apresentação dos padrões no treinamento. Na maioria dos casos usando o algoritmo básico apresentado na seção 6.4.1, também denominado algoritmo seqüencial ou incremental (Kohonen, 1997a), estes fatores aleatórios levam a mapeamentos diferentes, mas que possuem relações como, por exemplo, rotações de um mapa em relação a outro.

6.4.3.1 Dimensionalidade e tamanho do mapa

Normalmente escolhe-se mapas de dimensão 1 ou 2, este último mais freqüente devido à capacidade de visualização do mapeamento dos dados

na forma de um *display*. Entretanto, na maioria dos problemas de agrupamentos usa-se uma grade unidimensional, no qual o número de neurônios é igual ao número esperado de agrupamentos. A menos que se explicite contrariamente, usaremos mapas de dimensionalidade 2.

O algoritmo básico (Kohonen, 1997) fixa o número de neurônios N no início. Para problemas de agrupamentos, o ideal seria termos bem menos neurônios do que dados, de forma que a *taxa de ocupação* (t_O) ficasse em um nível razoável, onde t_O poderia ser definida como uma média do número total de padrões pelo número total de neurônios. Por exemplo, poderíamos desejar que t_O sempre fosse, no mínimo, 1. Quando temos grandes bases de dados isto se justifica, e certamente a escolha do tamanho do mapa deveria em princípio, supor $t_O >> 1$. Porém, em muitos casos práticos, pode ser útil dimensionar o mapa supondo que alguns neurônios serão inativos, i.e., não serão BMUs para nenhum padrão do conjunto de treinamento. Como veremos mais adiante, o SOM funciona como uma grade elástica tentando concentrar mais neurônios em regiões mais densas do espaço de atributos. À medida que a dimensionalidade do espaço de atributos aumenta, deveríamos alocar mais neurônios, de forma a tentar representar melhor os agrupamentos no modelo de protótipo distribuído. Por outro lado, ainda teremos alguns neurônios que farão parte de regiões de ligação entre dois ou mais agrupamentos, que inclusive podem ser inativos. Mapas de tamanho grande tornam o aprendizado muito lento, enquanto que mapas de tamanho muito pequeno, geram *U-matrizes*[1] também pequenas, o que irá dificultar bastante o uso de métodos de processamento e segmentação.

Pode-se ainda empregar um método dinâmico para fazer o crescimento do SOM. Uma das soluções seria aumentar o mapa inserindo novos neurônios entre os neurônios existentes. Os pesos dos novos neurônios

[1] Matrizes onde os elementos são distâncias entre neurônios, calculadas no espaço de pesos.

podem ser calculados por simples interpolação linear, i.e., fazendo-se uma média dos pesos dos neurônios na vizinhança de cada neurônio inserido. Assim, poderíamos treinar inicialmente uma rede *5×5* para um grande número de épocas, t_1, e em seguida, aumentar a rede, por exemplo, para *9×9,* inicializar os novos pesos por interpolação linear, e continuar o treinamento por mais *t* épocas, e assim sucessivamente. Esta seria uma das várias possíveis soluções para efetuar treinamento de um mapa de tamanho grande sem que o treinamento se torne excessivamente custoso. A motivação básica deriva do fato de que o gargalo do treinamento do SOM é a busca pelo neurônio vencedor, após a apresentação de um padrão na camada de entrada. Geralmente esta busca é feita de forma seqüencial, i.e., da ordem *O(N)*, onde *N* é o número de neurônios da rede. Fazendo com que $t_1 > t_2 > \ldots t_n$, poderíamos obter um ganho de tempo bastante sensível, devido a que o custo computacional do treinamento para t_i épocas seria da ordem de $O(N.t_i)$ para uma rede com *N* neurônios, enquanto que pelo método proposto, o custo teria ordem:

$O(N_1.t_1 + N_2.t_2 + \ldots + N_n.t_n)$, condicionando que $N = N_n$ e que $t_i = \sum_{k=1}^{n} t_k$.

6.4.3.2 Conectividade entre neurônios e topologia da rede

Como descrito anteriormente, no caso bidimensional, geralmente usa-se um arranjo retangular no qual os elementos são conectados aos vizinhos nos padrões de conectividade 4 ou 6, implicando na topologia retangular ou hexagonal. Os elementos que se situam nas extremidades do mapa podem ainda ser conectados ou não. Neste trabalho, foram usados mapas com topologias e conectividades retangulares, a menos que se explicite o contrário.

6.4.3.3 Inicialização dos pesos

Antes de iniciarmos a fase de aprendizado devemos escolher ou inicializar os pesos sinápticos. Apesar do SOM ser relativamente robusto em relação a inicialização, métodos que pudessem inicializar os pesos de forma adequada poderiam facilitar a convergência do algoritmo. A forma mais comum de inicialização é a randômica, onde atribuímos valores pequenos aleatórios aos pesos. Pode-se inicializar vetores pegando aleatoriamente padrões no conjunto de dados, e copiando estes padrões aos vetores de pesos. Uma outra forma seria pegar valores máximos e mínimos em cada dimensão e inicializar, de forma ordenada, a grade de neurônios, interpolando o espaço de acordo com o número de neurônios.

Recentemente, Kohonen defendeu a idéia da inicialização linear, sendo preferível em relação às descritas anteriormente por possibilitar irmos diretamente para a fase de convergência do algoritmo de treinamento (Kohonen, 1997a, pg. 115). Esta forma de inicialização será usada nos experimentos deste trabalho, a menos que se explicite o contrário. Descreveremos, a seguir, de forma bastante abreviada, os conceitos deste método.

A inicialização linear de um mapa com espaço de saída com dimensão k é feita utilizando-se dos k componentes principais da matriz de autocorrelação do conjunto de dados X. Considere o caso de um SOM bidimensional ($k = 2$). Autovalores e autovetores são definidos por $A \cdot y = e \cdot y$, onde A é a matriz de autocorrelação de dados, y é um autovetor e e o autovalor correspondente.

Os pesos, $m_i(0)$, são inicializados de forma ordenada na direção do subespaço linear obtido pelos autovetores, ortogonais, correspondentes aos dois maiores autovalores, sendo seu centróide coincidente com a média do

conjunto de dados, $\boldsymbol{X}$. Seja y_1 e y_2 os autovetores escolhidos. As coordenadas do neurônio (i, j) podem ser expressas por:

$$s\left[\left(i-\frac{\max_i}{2}\right)\cdot y_1+\left(j-\frac{\max_j}{2}\right)\cdot y_2\right]$$

onde max_i e max_j representam o tamanho do mapa bidimensional, escolhido pelo usuário, e s é uma constante selecionada de forma adequada.

6.4.3.4 Funções para decaimento da vizinhança ao redor do *BMU* e da taxa de aprendizagem

A função de vizinhança $h_{ci}(t)$, dada pela equação (6.6), tem uma importância fundamental no SOM, atuando como um núcleo de suavização sobre a grade de neurônios. Para convergência do algoritmo, é necessário que $h_{ci}(t) \rightarrow 0$ quando $t \rightarrow \infty$. A função $h_{ci}(t) \approx h(\| r_c - r_i \|, t)$, onde r_c e $r_i \in \Re^2$, são as posições dos neurônios c e i na grade de neurônios, respectivamente. À medida que $\| r_c - r_i \|$ aumenta, $h_{ci}(t) \rightarrow 0$.

O algoritmo original do SOM (Kohonen, 1982a) define uma vizinhança do tipo bolha ou circular, i.e., dado um raio $r(t)$ do neurônio vencedor, no passo t, todos os neurônios dentro deste raio possuem h igual a 1. Seja $N_c(t)$ o conjunto de neurônios satisfazendo esta condição. Desta forma, $h_{ci}(t) = \alpha(t)$ para todos os neurônios $i \in N_c(t)$ e $h_{ci}(t) = 0$ caso contrário ($i \notin N_c(t)$). A Figura 6.3 ilustra o efeito no tempo de $N_c(t)$.

Outra forma bastante usada é a vizinhança do tipo Gaussiana,

$$h_{ci}(t) = \alpha(t)\cdot\exp\left(\frac{-\|r_c - r_i\|^2}{2\cdot\sigma^2(t)}\right) \qquad \textbf{(6.13)}$$

onde σ pode ser definido como o raio de $N_c(t)$. Deve-se sempre escolher raio inicial $N_c(0)$ relativamente grande, por exemplo, a metade do diâmetro da rede. Escolher $N_c(0)$ pequeno pode fazer com que o algoritmo não gere uma ordenação adequada (um meta-estado).

Como descrito na equação (6.6), $h_{ci}(t)$ também é proporcional a $\alpha(t)$, e ambos, componentes de $h_{ci}(t)$, $h(\| r_c - r_i \|, t)$ e $\alpha(t)$, devem ser escolhidas como funções monotônicamente decrescentes com o tempo, t. Em relação a $\alpha(t)$ duas condições são suficientes e necessárias:

$$\sum_{t=1}^{\infty} \alpha^2(t) < \infty \quad e \quad \sum_{t=1}^{\infty} \alpha(t) = \infty \tag{6.14}$$

A escolha de $\alpha(t)$ deve ser feita de forma criteriosa principalmente em mapas de grande dimensão. De acordo com (6.14), vemos que $\alpha(t)$ é limitada, e inicialmente deveríamos escolher $\alpha(t)$ próximo a 1, possibilitando seu decaimento com o tempo, que pode ser feito, por exemplo, de forma exponencial, linear, ou inversamente proporcional a t. O algoritmo em lote (seção 6.4.4) elimina o problema de escolher uma seqüência ótima para $\alpha(t)$.

6.4.3.5 Número de épocas

Como o treinamento é um processo estocástico, a precisão do mapeamento obtido depende do número de épocas. O algoritmo original (Kohonen, 1982a) estabelece duas fases, uma de ordenação inicial, e outra de convergência. A primeira duraria, por exemplo, cerca de 1000 épocas, enquanto a convergência deveria ser mais demorada, por exemplo, 100.000 épocas.

Em relação à apresentação de dados à rede, passo 2, o algoritmo convencional seleciona padrões aleatoriamente do conjunto de dados durante

uma época. Porém, caso existam padrões raros em uma base de dados, e seja importante obter uma representação deles no SOM, podemos usar esquemas que dêem ênfase a tais padrões, forçando reapresentações do mesmo objeto numa mesma época de treinamento. Isto pode ser feito modificando a probabilidade de ocorrência do padrão $\boldsymbol{x}$, $p(\boldsymbol{x})$, justificado apenas quando se têm um bom conhecimento *a priori* do conjunto $\boldsymbol{X}$.

6.4.4 Algoritmo em lote ou paralelo

Um método de tornar o resultado do mapeamento insensível à seqüência de apresentações de padrões à rede é deixar para atualizar os pesos apenas no final de uma época. Isto pode ser feito somando-se a média das contribuições de todos os padrões para cada neurônio. Teremos então um deslocamento médio que na prática tem conduzido a melhores resultados que o algoritmo convencional. Em relação ao algoritmo apresentado na seção 6.4.1, a equação 6.5 teria no termo mais à direita um somatório na forma como apresentada na equação 6.15,

$$m_i(t_e+1) = m_i(t_e) + \frac{1}{n}\sum_{l=1}^{n}\{h_{ci}(t_l).[x(t_l) - m_i(t_l)]\} \qquad \textbf{(6.15)}$$

Onde t_e e t_l são iterações das épocas e dos passos dentro das épocas, respectivamente, $\boldsymbol{x}(t_l)$ é o padrão de treinamento geralmente escolhido de forma aleatória do conjunto de dados no tempo t_l e $h_{ci}(t_l)$ é o núcleo de vizinhança ao redor do neurônio vencedor c no tempo t_l, e n é o número de padrões usados no treinamento. Geralmente escolhe-se um valor pequeno e fixo para a taxa de aprendizado $\alpha(t)$, componente de $h_{ci}(t_l)$, por exemplo, 0.05.

A implementação prática deste algoritmo pode ser feita de forma simples alocando uma lista de tamanho n para cada neurônio. A cada iteração

pode ser usada a equação (6.5) e a quantidade de deslocamento para cada neurônio $\boldsymbol{m_i}$, i.e., $_\boldsymbol{m_i}(t_l)$, em cada iteração t_l pode ser acumulada nesta lista, na posição l. No final de cada época soma-se as contribuições para cada neurônio e limpa-se a lista. Por outro lado, pode-se ter uma variável associada a cada neurônio, que seria a simplificação de uma lista de tamanho 1, na qual as contribuições são agregadas ao longo das iterações dentro de uma época. A vantagem do uso de uma lista de tamanho n é que podemos extrair alguma estatística a mais dos deslocamentos dos pesos no espaço dentro de uma época e em algumas épocas consecutivas. Por exemplo, poderíamos extrair informações dos deslocamentos de cada neurônio para cada padrão nas últimas três épocas para saber a trajetória média que o neurônio está realizando no espaço e usar esta informação para acelerar a convergência do algoritmo. A desvantagem do algoritmo em lote é a necessidade de se dispor de todos os dados antes do início do treinamento.

6.4.5 Um algoritmo mais eficiente para redução do tempo de treinamento

Uma maneira de diminuir o tempo de treinamento seria diminuir o tamanho do raio da busca pelo neurônio vencedor a um dado padrão. Como esta busca é feita de forma seqüencial, como descrito na seção 6.4.2, ela é uma das operações que mais consomem tempo no treinamento do SOM. Usando a propriedade de que, à medida que o treinamento avança os centros de ativação especializados em padrões vão surgindo, podemos supor que quanto mais treinamos um SOM, maior será a probabilidade de que o vencedor, c, para um padrão x em uma dada época t_e seja o mesmo vencedor na época anterior t_{e-1}, ou que esteja nas proximidades de c. Assim, podemos fazer com que cada padrão x tenha uma variável associada ao último neurônio vencedor, $c(x)$, na época anterior, e efetuar a busca pelo vencedor na época atual apenas em uma sub-região do mapa delimitada por um raio de busca que decresce com o tempo, $R(t_e, c)$. Pode-se usar qualquer formato de função monotônica

decrescente para $R(t_e, c)$, porém devemos preferir funções suaves e que possibilitem no final do treinamento um raio de busca superior à vizinhança final $h(d, t)$. Assim, teríamos inicialmente R igual ao tamanho do mapa, e poderíamos fazê-lo decrescer à medida que o número de épocas aumentasse, porém sempre mantendo $R(t_e, c) > h(d, t)$. O uso deste algoritmo será de grande importância principalmente à medida que usemos mapas de maior tamanho e dimensão. O número total de neurônios pode ser bastante elevado, por exemplo, um mapa com *grade* de dimensão *4* contendo $10 \times 10 \times 10 \times 10$ neurônios possui 10^4 neurônios ao todo. Cada iteração de cada época significa buscar o vencedor c entre 10^4 neurônios. Decrescendo este espaço de busca, por exemplo, em uma dada época, t_e, centrado no vencedor do padrão $\boldsymbol{x}$ na última época, $c(t_{e-1}, \boldsymbol{x})$, poderíamos ter um raio, por exemplo, de tamanho 5, o que daria $5 \times 5 \times 5 \times 5 = 625$ neurônios, contra 10^4, ou seja, uma redução para 6.25% do espaço de busca original. Esta redução de tempo integrada para todas as iterações e para todas as épocas resulta em uma grande redução do tempo total do treinamento.

6.4.6 Exemplo de uso do SOM

Esta seção apresenta um exemplo simples do uso do SOM para o caso de entrada bidimensional. A Figura 6.6 ilustra um conjunto de dados gerado por uma mistura de três Gaussianas bivariadas, com vetor de médias $\mu = \{ \mu_1, \mu_2, \mu_3 \} = \{ (0, 0), (1, 0), (0.5, 0.866) \}$. O número total de objetos é 375, sendo 125 objetos por classe. A matriz de covariâncias, para as três classes é $\sigma^2 \cdot I$, onde σ usado foi 0.15.

A Figura 6.7.a ilustra a grade de um mapa unidimensional com 40 neurônios após inicialização linear utilizando os dados apresentados na Figura 6.6. Após 1000 iterações do algoritmo em lote, temos a grade como mostrado na Figura 6.7.b, na qual podemos visualizar como a estrutura concentrou

neurônios em regiões de maior densidade de pontos. A Figura 6.7.c ilustra o histograma de vencedores, *H*, ou seja, quantas vezes o neurônio *i* foi vencedor após o mapa estar ordenado. Por exemplo, o neurônio 3 teve 15 padrões associados a ele.

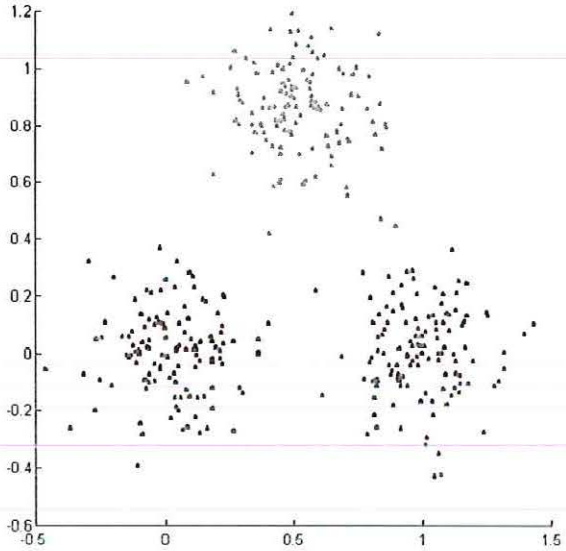

Figura 6.6 – Conjunto de dados gerado artificialmente.

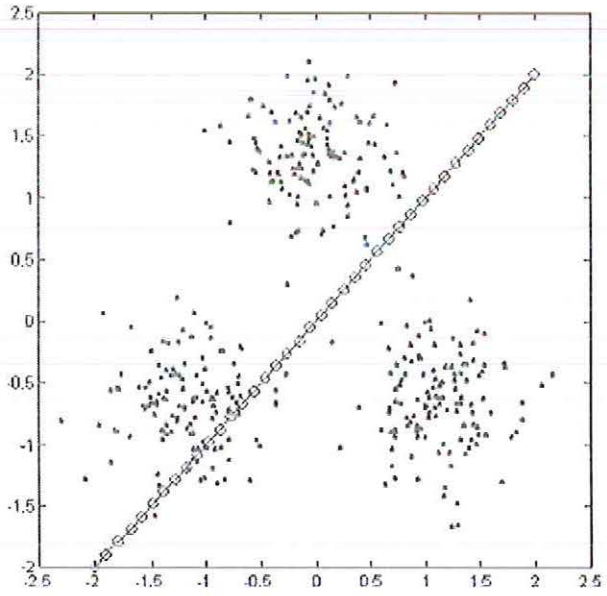

Figura 6.7.a – Grade do SOM 40x1 após inicialização linear.

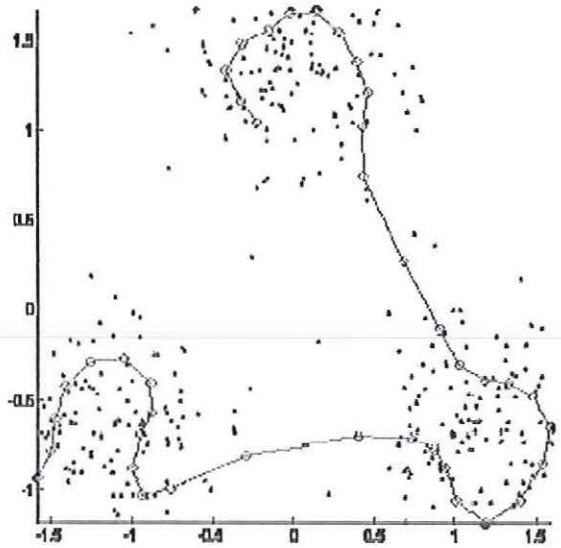

Figura 6.7.b – Grade do SOM 40x1 após 1000 iterações batch.

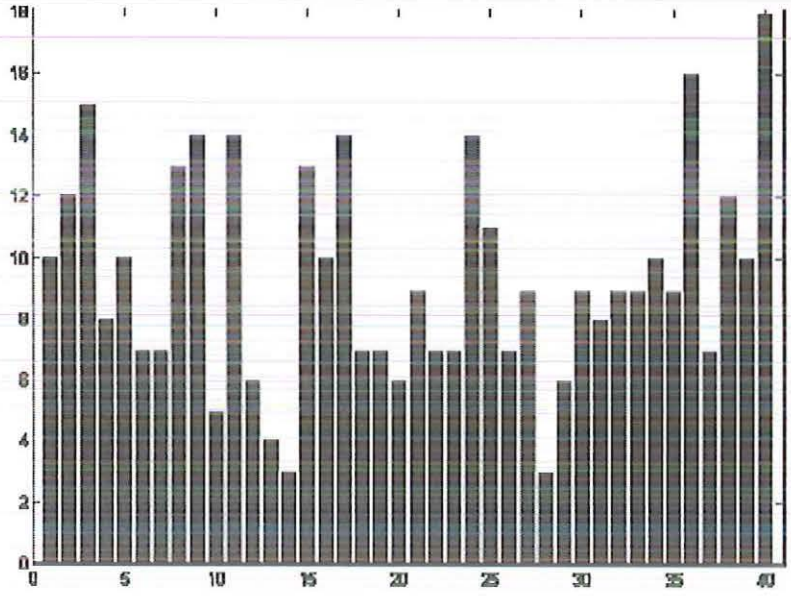

Figura 6.7.c – Histograma de vencedores para o SOM 40x1.

Para o caso de um SOM bidimensional, escolhemos o tamanho 10×10 para o mapa e o inicializamos de forma linear. O resultado é apresentado na Figura 6.8. Após 1000 iterações do algoritmo em lote (*batch*) obteve-se a configuração mostrada na Figura 6.9. Novamente, note que houve uma concentração de neurônios nas regiões onde há maior densidade de objetos.

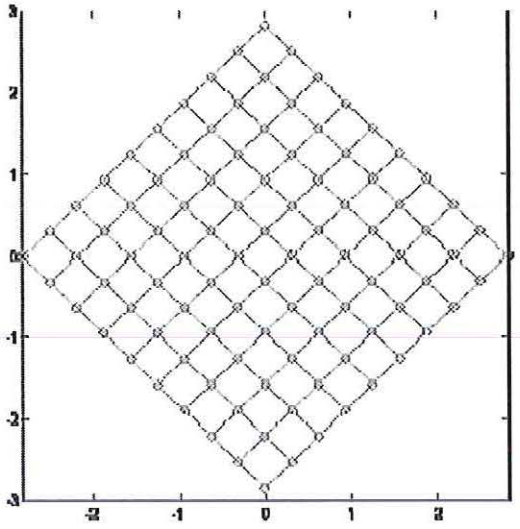

Figura 6.8 – Grade após inicialização linear de uma rede SOM de tamanho 10x10.

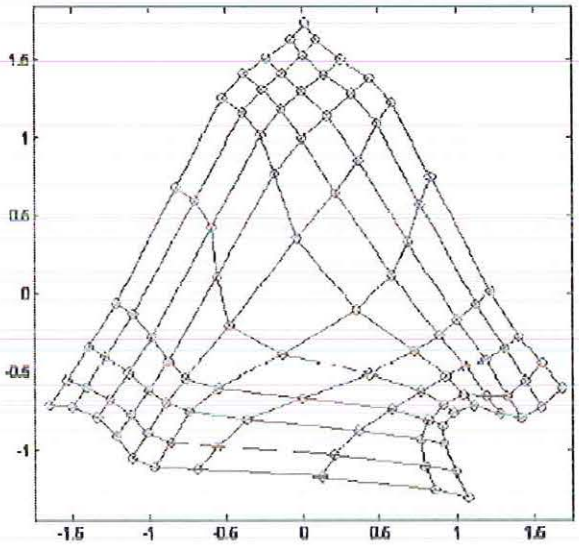

Figura 6.9 – Grade do SOM 10x10 após 1000 iterações do algoritmo em lote e inicialização linear.

O histograma de vencedores, *H*, neste caso é também bidimensional e está apresentado na forma tabular na Figura 6.10, representando quantas vezes o neurônio *i* foi vencedor após o mapa estar ordenado. Por exemplo, o neurônio (1, 1) obteve 6 padrões na sua área de quantização, ou de influência, enquanto que o neurônio (10, 10) obteve 10 padrões. Alguns neurônios obtiveram 0 vencimentos. Alguns autores chamam estes neurônios de células mortas. À medida que aumentamos o número de neurônios em uma rede,

constata-se um aumento de neurônios mortos. Pode ser conveniente definir grau de ativação como um valor mínimo, φ, que os neurônios deveriam possuir para serem considerados para análise. Neurônios inativos podem ser definidos como neurônios cujo número de vencimentos seja inferior a φ, i.e., se $H(i, j) \leq \varphi$. Geralmente é mais conveniente trabalhar com percentuais para φ do que com valores como os apresentados na Figura 6.10.

6	3	0	3	5	8	3	8	6	8
3	3	1	2	3	2	2	3	5	5
2	4	1	2	5	6	9	3	6	7
7	1	3	0	2	6	1	5	3	4
1	2	4	0	1	2	0	0	0	1
4	6	0	5	1	1	3	5	6	8
1	3	5	5	1	4	2	9	3	5
12	5	3	3	2	3	2	3	8	5
3	1	6	3	0	4	4	8	3	4
5	5	5	2	1	6	7	2	6	10

Figura 6.10 – Histograma de vencedores para o SOM 10x10.

A Figura 6.11 ilustra a quantização obtida pelo SOM, as linhas simbolizando vizinhança entre os neurônios, mostradas na Figura 6.9 foram eliminadas para facilitar a visualização. Os elementos ilustrados pelo símbolo (+) são os neurônios, enquanto que os dados são os pontos (•). Cada objeto é ligado ao neurônio mais próximo (vencedor) por uma linha. Note a existência de neurônios mortos, i.e., $H(i, j) = 0$. Geralmente tais neurônios aparecem em regiões com baixa densidade de probabilidade de objetos, sendo sua existência decorrente da estrutura da grade elástica do SOM.

Uma maneira de pensar como ocorre a quantização no SOM é através do diagrama de Voronoï. Cada neurônio possui uma região de influência (ou célula de Voronoï) no espaço, na qual todos os pontos são mais próximos a tal neurônio do que a qualquer outro. Uma forma de visualizar a classificação de cada padrão em cada neurônio é através da superfície de influência dos neurônios. O objetivo é visualizar a configuração de um mapa

com dimensão dos dados de entrada 2D, onde a distância de um ponto qualquer do espaço ao neurônio mais próximo é plotada no eixo z. A Figura 6.12 ilustra a superfície de influência em 2D. Pode-se limitar a influência de cada neurônio a um valor máximo, ρ. Por exemplo, fazendo $\rho = 0.5$ para todos os neurônios. Este mecanismo pode, por exemplo, prevenir o sistema contra valores discrepantes (*outliers*).

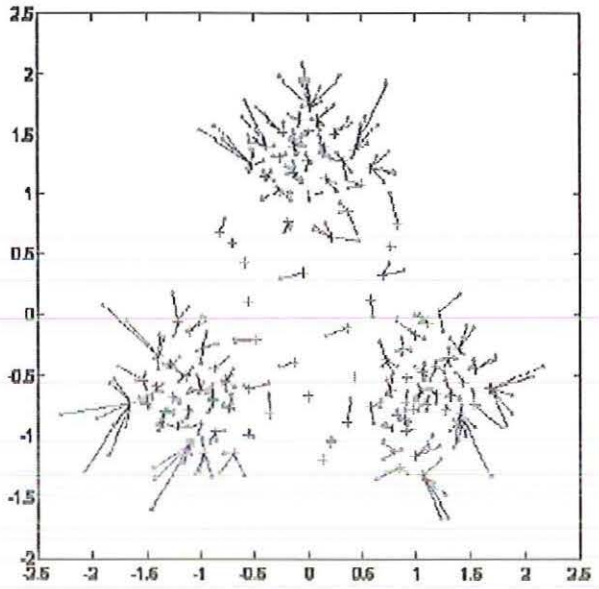

Figura 6.11 – Quantização obtida após 1000 iterações.

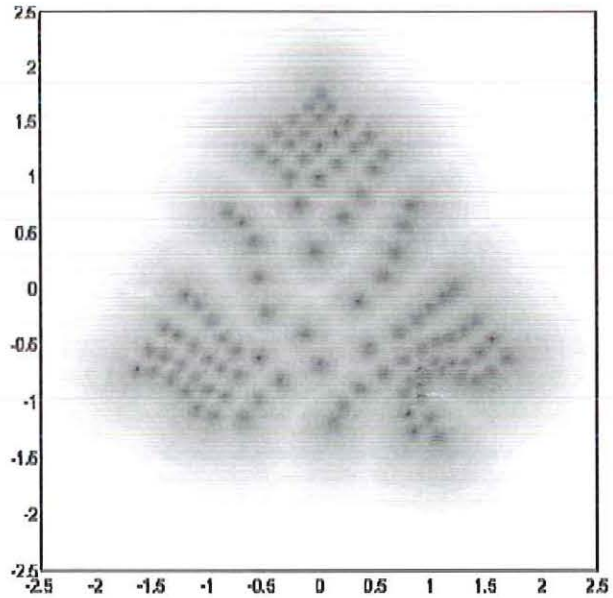

Figura 6.12 – Superfície de influências dos neurônios em 2D.

Apesar de todos os neurônios serem importantes, a configuração obtida após o treinamento pode ser melhor analisada caso olhemos a superfície de influência dos neurônios que realmente estão ativos, para um dado φ escolhido. A Figura 6.13 ilustra a quantização caso desconsiderássemos neurônios cujo $H(i, j)$ seja menor ou igual a 1. A Figura 6.14 ilustra a superfície de influências para este caso. Note que já é possível perceber a existência de três grandes centros de atração, separados por uma borda, ilustrada pelas regiões mais claras da imagem.

Sendo ainda mais rigoroso, i.e., aumentando φ para 7, obtemos as figuras apresentadas em 6.15 - 6.16. Fica evidente a existência de três grandes centros de atração (ver Fig. 6.17). Vê-se que à medida que aumentamos φ, descobrimos centros de atração que correspondem a agrupamentos de neurônios mais fortes, pois retiramos neurônios inativos. Porém, deve-se manter em mente que a quantização do SOM não prevê exclusão de neurônios inativos, e este artifício pode ser usado, como será demonstrado posteriormente, para facilitar a segmentação da grade de neurônios.

Infelizmente a superfície de influências dos neurônios (ou dos protótipos), assim como o diagrama de Voronoï, não são de muita utilidade quando a dimensão do espaço de entrada é maior que 2, sendo seu uso mais recomendado para entendermos o processo de quantização efetuado pelo SOM.

Outros métodos serão mostrados na próxima seção (por exemplo, a *U-matrix*, e o mapa de ativações dos neurônios) que possibilitam a descoberta de agrupamentos em problemas com dimensões do espaço de entrada arbitrárias.

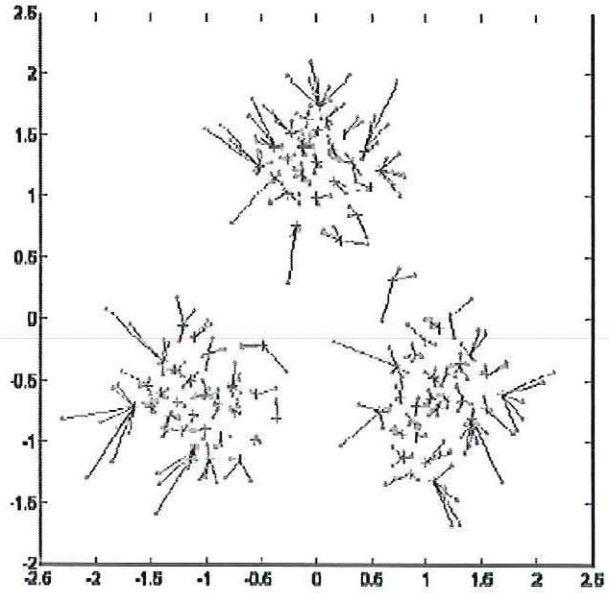

Figura 6.13 – Quantização obtida considerando apenas neurônios ativos com $H(i, j) > 1$.

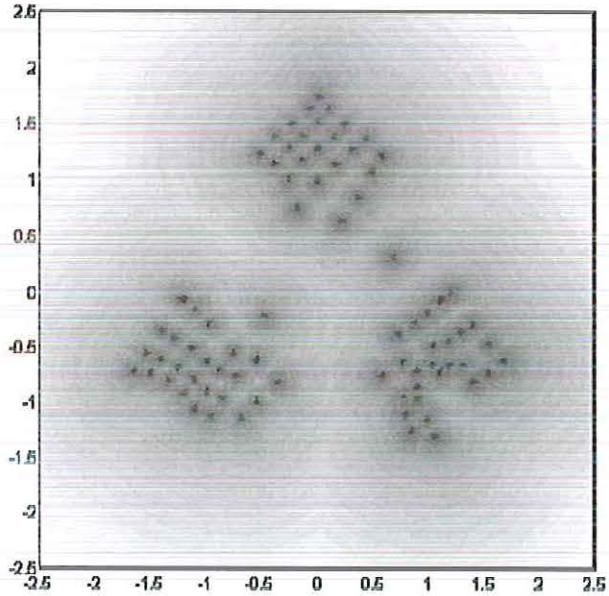

Figura 6.14 – Superfície de influências para a configuração de neurônios, apresentada na Figura 6.13, $H(i, j) > 1$.

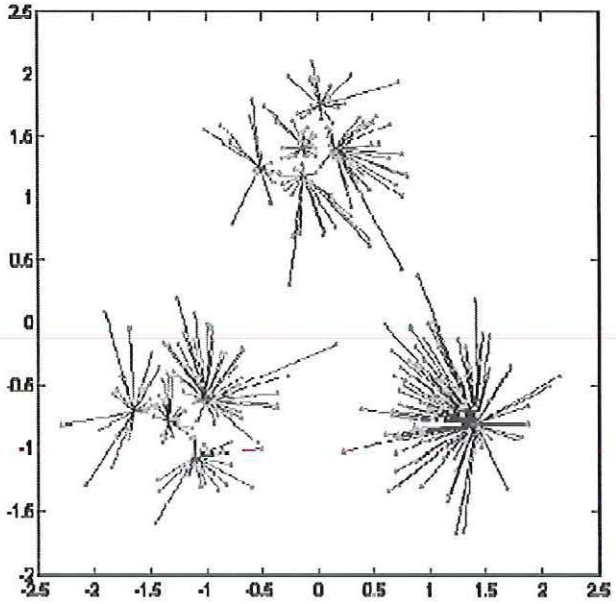

Figura 6.15 – Quantização obtida considerando apenas neurônios ativos com $H(i, j) > 7$.

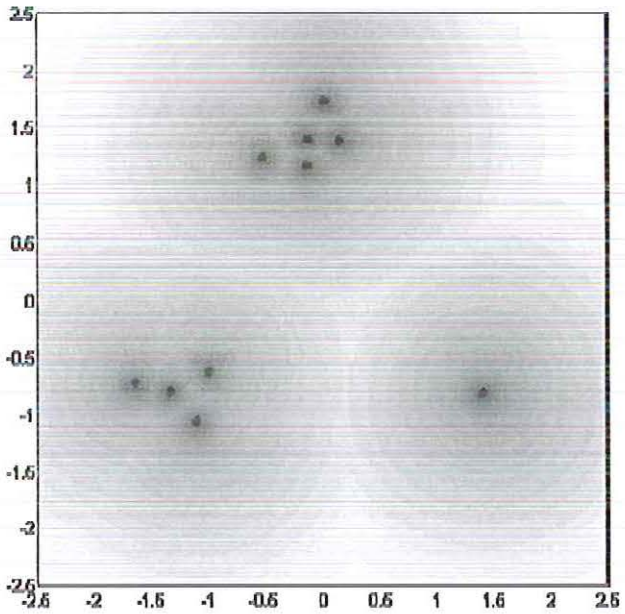

Figura 6.16 – Superfície de influências para a configuração de neurônios apresentada na Figura 6.15, $H(i, j) > 7$.

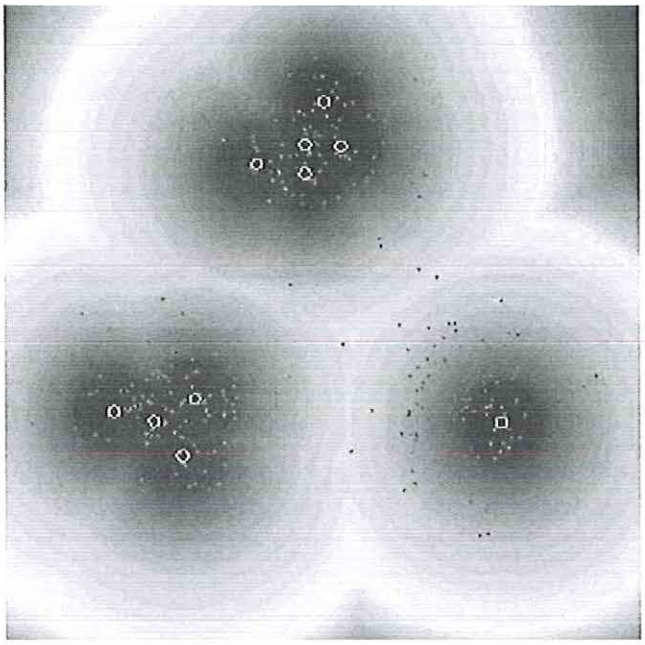

Figura 6.17 – Superfície de influências para a configuração de neurônios apresentada na Figura 6.15, $H(i, j) > 7$, mostrando os neurônios e os objetos, com área de influência dos neurônios, ρ limitado a 0.5.

6.5 Segmentação e rotulação dos mapas de Kohonen

O SOM é usado para mapear um espaço de entrada p-dimensional, contendo n padrões, para uma grade de neurônios uni- ou bidimensional, com os objetivos de quantizar o espaço de entrada e representar da melhor forma possível a topologia original em um espaço de menor dimensão. Uma vez treinado, podemos rotular neurônios caso tenhamos, além da informação dos padrões, as suas respectivas classes. Padrões são apresentados ao mapa e o neurônio vencedor será o mais similar, ou o mais próximo, de acordo com o critério de similaridade escolhido. Diferentemente de PCA, onde o resultado da projeção é contínuo, a projeção dos dados no SOM é discreta. O resultado de cada apresentação é um índice (i, j) denotando o neurônio vencedor.

Para efetuar análise de agrupamentos, este mapeamento topologicamente ordenado geralmente não é suficiente, pois a informação de distâncias entre os neurônios é perdida. A saída de um SOM para um dado

padrão inserido é geralmente o índice do neurônio vencedor c, no caso bidimensional um par de valores (i, j), e o nível de ativação diretamente relacionado à quantização (no nosso caso a distância do padrão ao neurônio c, computado no espaço de pesos).

A visualização das relações entre os neurônios para um problema em que o vetor de entrada possui uma dimensão maior que 2 ou 3 torna-se bastante difícil. A representação tradicional da grade, Diagrama de Voronoï e/ou superfície de influências, deve ser substituída por métodos alternativos.

6.5.1 Visualização dos mapas de kohonen a *U-matrix*

Um método de visualização de um SOM treinado, denominado a matriz de distâncias unificadas, ou *U-matrix*, foi desenvolvido por A. Ultsch (1993a,b) com o objetivo de permitir a detecção visual das relações topológicas dos neurônios. A idéia básica é usar a mesma métrica que foi utilizada durante o treinamento para calcular distâncias entre pesos sinápticos de neurônios adjacentes. O resultado é uma imagem $f(x, y)$, na qual as coordenadas de cada pixel (x, y) são derivadas das coordenadas dos neurônios na grade do mapa, ex. $(1,1)$, $(1, 2)$ ... $(X, Y) \rightarrow (1,1)$, $(1, 2)$ ... $(2*X-1, 2*Y-1)$, e a intensidade de cada *pixel* na imagem $f(x, y)$ corresponde a uma distância calculada. Pode-se pensar uma imagem como uma função tridimensional em que o valor do pixel na coordenada (x, y) é representado por um ponto na coordenada z. Neste caso, teremos uma superfície em 3D cuja topografia revela a configuração dos neurônios obtida pelo treinamento. Vales, neste relevo topográfico, correspondem a regiões de neurônios que são similares, enquanto que montanhas, i.e., valores relativamente elevados na *U-matrix*, refletem a dissimilaridade entre neurônios vizinhos e podem ser associadas a regiões ou neurônios em fronteiras de agrupamentos. Regiões de vales serão candidatas para representar agrupamentos de neurônios. Pelo fato de

geralmente a *U-matrix* ser uma imagem relativamente complexa, principalmente em problemas de análise de dados reais, geralmente seu uso é restrito a visualização, sendo uma ferramenta de auxílio na separação manual dos agrupamentos de um SOM.

Apesar da descrição a seguir ser para um mapa cujos neurônios possuem vizinhança retangular, a lógica pode ser estendida, por exemplo para vizinhança hexagonal. Considere um mapa retangular de tamanho $X \times Y$. Seja $[b_{x,y}]$ a matriz de neurônios e $[w_{i_{x,y}}]$ a matriz de pesos. Para cada neurônio em b existem três distâncias d_x, d_y e d_{xy}, na *U-matrix*, a seus vizinhos (ver figuras 6.18 e 6.19).

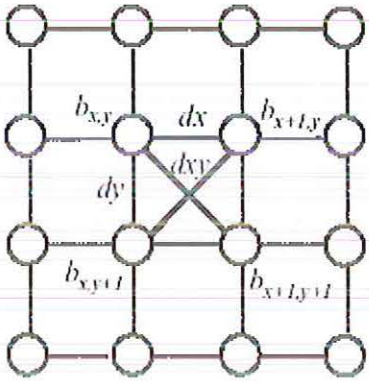

Figura 6.18 – As três distâncias da *U-matrix*

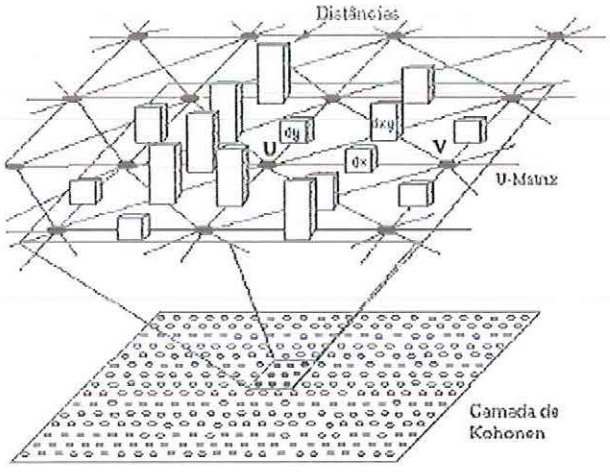

Figura 6.19 – Representação 3D da *U-matrix* (adaptado de Ultsch, 1993a).

Considerando distâncias Euclidianas, no caso da topologia da grade de neurônios ser retangular, as distâncias d_x, d_y e d_{xy} são definidas como:

$$dx(x,y) = \left\| b_{x,y} - b_{x+1,y} \right\| = \sqrt{\sum_i \left(w_{i_{x,y}} - w_{i_{x+1,y}} \right)^2} \tag{6.16}$$

$$dy(x,y) = \left\| b_{x,y} - b_{x,y+1} \right\| = \sqrt{\sum_i \left(w_{i_{x,y}} - w_{i_{x,y+1}} \right)^2} \tag{6.17}$$

$$d_{xy}(x,y) = \frac{1}{2}\left(\frac{\left\| b_{x,y} - b_{x+1,y+1} \right\|}{\sqrt{2}} + \frac{\left\| b_{x,y+1} - b_{x+1,y} \right\|}{\sqrt{2}} \right) = \tag{6.18}$$

$$d_{xy}(x,y) = \frac{1}{2\sqrt{2}}\left[\sqrt{\sum_i \left(w_{i_{x,y}} - w_{i_{x+1,y+1}} \right)^2} + \sqrt{\sum_i \left(w_{i_{x,y+1}} - w_{i_{x+1,y}} \right)^2} \right]$$

Estas distâncias, calculadas no espaço dos pesos, são plotadas em uma matriz U de tamanho $(2X\text{-}1) \times (2Y\text{-}1)$. A *U-matrix* combina as três distâncias, ou gradientes, considerando todos os componentes do SOM. Para cada neurônio de b, as distâncias para os vizinhos (se estas existirem) tornam-se dx, dy e dxy, e a U-Matrix é preenchida de acordo com a Tabela 6.1,

TABELA 6.1 - ESQUEMA PARA PREENCHIMENTO DOS ELEMENTOS DA U-MATRIX

i	j	(i,j)	$U_{i,j}$
I	P	$(2x+1, 2y)$	$dx(x,y)$
P	I	$(2x, 2y+1)$	$dy(x,y)$
I	I	$(2x+1, 2y+1)$	$dxy(x,y)$
P	P	$(2x, 2y)$	$du(x,y)$

onde as abreviações *'I'* e *'P'* referem-se ao índice ou posição do neurônio, sendo ímpar e par, respectivamente. A equação 6.19 apresenta os elementos da *U-matrix*, preenchida de acordo com a Tabela 6.1.

$$\begin{bmatrix} du(0,0) & dx(0,0) & du(1,0) & \cdots & du(X-1,0) \\ dy(0,0) & dxy(0,0) & dy(1,0) & \cdots & du(X-1,0) \\ du(0,1) & dx(0,1) & du(1,1) & \cdots & du(X-1,1) \\ dy(0,1) & dxy(0,1) & dy(1,1) & \cdots & du(X-1,1) \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ du(0,Y-1) & du(0,Y-1) & du(1,Y-1) & \cdots & du(X-1,Y-1) \end{bmatrix} \quad \textbf{(6.19)}$$

Existem pelo menos duas possibilidades para o cálculo de $du(x, y)$: pode-se usar o valor médio ou a mediana dos elementos circunvizinhos. Seja $C = (c_1, c_2, \ldots c_k)$ os valores dos elementos circunvizinhos de $U_{2x,2y}$ aparecendo na forma de um vetor ordenado com cardinalidade k ($k = |C|$). No nosso caso de topologia retangular, $k = 8$. No caso de $du(x, y)$ ser o valor mediano, temos;

$$du(x,y) = \begin{cases} c[(k+1)/2] & \text{se } k \text{ for } \textit{ímpar} \\ \dfrac{c(k/2)+c[(k+1)/2]}{2} & \text{se } k \text{ for } \textit{par} \end{cases}$$

onde c(k), $k = 1, 2, \ldots K$, $K \leq 8$, denotam os elementos circunvizinhos ordenados de forma crescente de magnitude.

No caso de $du(x, y)$ ser o valor médio de C, temos;

$$du(x,y) = \tilde{c} = \frac{1}{k}\sum_{i=1}^{k} c_i$$

Para o SOM de tamanho *10×10* apresentado na Figura 6.9, treinado com 1000 iterações do algoritmo em lote, e inicializado de forma linear, a *U-matrix* correspondente é mostrada na Figura 6.20, na forma 3D, e na Figura 6.21, na forma de uma imagem bidimensional. Note que as distâncias foram escalonadas linearmente, de forma que a distância máxima seja *1* e a mínima *0*. Olhando a Figura 6.21 percebe-se a existência de três grandes regiões, uma à esquerda, e duas à direita, sendo uma na parte superior e a outra na parte inferior da figura. As bordas entre estas regiões, bastante detectáveis ao olho

humano, devem-se principalmente à natureza relativamente simples do problema, i.e., os agrupamentos gerados artificialmente possuem uma separação tal que foi possível ao SOM obter uma configuração que concentrasse neurônios nas regiões dos agrupamentos, sobrando poucos neurônios em regiões de baixa densidade. Problemas em que os agrupamentos estão menos separados causam uma degradação das bordas da *U-matrix*, o que pode tornar sua segmentação extremamente difícil.

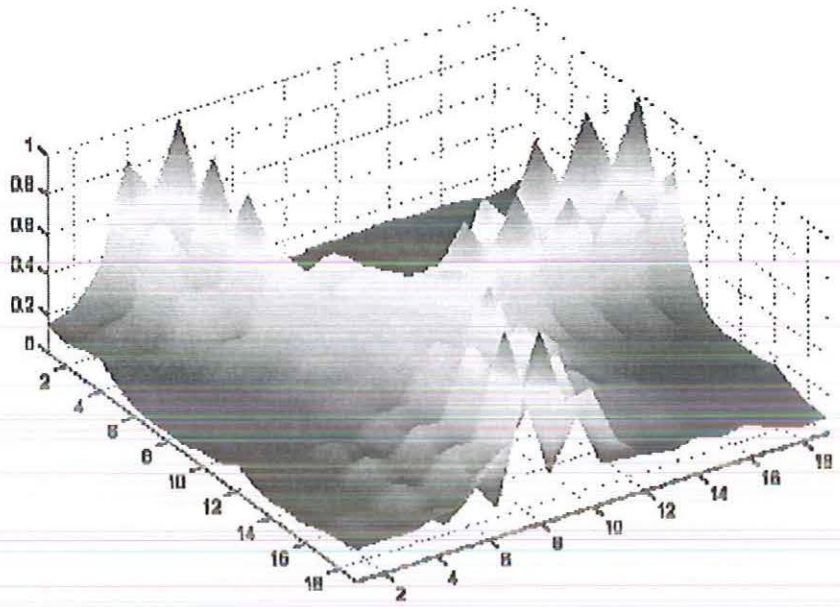

Figura 6.20 – *U-matrix* na forma 3D do SOM 10x10 apresentado na Figura 6.9.

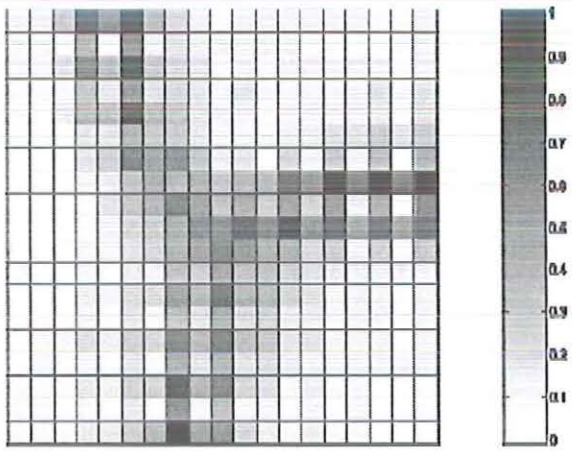

Figura 6.21 – *U-matrix*, na forma de imagem bidimensional, do SOM 10x10 apresentado na Figura 6.9.

Mesmo neste problema relativamente simples, pode-se notar que em certas regiões as bordas são mais fortes do que em outras. Isto se deve aos neurônios de ligação da grade que podem inclusive estar inativos. Olhando para a Figura 6.11 pode-se perceber neurônios (marcados com o símbolo +) que não estão representando nenhum objeto do conjunto de dados, entretanto foram usados nos cálculos da *U-matrix*, o que sem dúvida contribuiu para uma pequena degradação das bordas em regiões centrais, por exemplo, (veja a Figura 6.20). Um modo de atenuar o efeito de neurônios inativos é tentar isolá-los do processo de cálculo da *U-matrix*, porém, a eliminação destes neurônios causaria buracos na rede.

6.5.2 Segmentação da U-matrix

A partir do modelo de imagem apresentado na *U-matrix* iremos efetuar a segmentação e rotulação do SOM usando apenas os padrões, sendo que cada neurônio deverá receber um código de acordo com o agrupamento a que pertence. Uma vez dispondo do SOM rotulado, os dados são então classificados de acordo com a classe do agrupamento de neurônios onde se encontra o neurônio que está mapeando o respectivo padrão.

As tarefas de classificação serão realizadas após a segmentação da *U-matrix,* esta etapa é crucial para a minimização de erros de classificação, visto que na maioria das aplicações práticas a *U-matrix* se apresenta com muitos mínimos regionais e bordas difusas, causados por exemplo, por ruídos. É importante notar que o modelo de imagem da *U-matrix,* com vales caracterizando os agrupamentos de neurônios, é adequado ao tratamento usando algoritmos de segmentação morfológicos. Em nossa abordagem usamos a transformada *watershed* (Meyer & Beucher,1990), que tem sido considerada como uma das ferramentas de segmentação mais eficientes em processamento de imagens.

Basicamente, segmentar uma imagem consiste em subdividir a imagem em suas partes ou objetos constituintes. Imagens tratadas por computador são discretizadas tanto em dimensões quanto em intensidade. A representação convencional de uma imagem é considerá-la uma função $f(x, y)$, onde a amplitude f nas coordenadas x e y é proporcional à intensidade ou brilho, denominado nível de cinza quando a imagem é monocromática[2]. Geralmente, convenciona-se que x e y pertencem ao conjunto de números inteiros, ($\forall\ x, y \in \mathbb{Z}$), e consideraremos os limites para as coordenadas x e y como $[0, x_{max}]$ e $[0, y_{max}]$. Em relação a f, também discreta, contém uma faixa de valores entre um intervalo f_{min} e f_{max}, dependente da aplicação. O número de níveis diferentes de intensidades[3], n_i depende da discretização obtida na imagem. No caso mais comum, e que é usado nesta tese, $[f_{min}, f_{max}] = [0, 255]$ e n_i é 1, ou seja, há 256 níveis de cinza na imagem f. Portanto neste trabalho as imagens consideradas são monocromáticas e geradas artificialmente, veja por exemplo as Figuras 6.20 e 6.21, onde se busca segmentar as regiões de vale que estão associadas aos agrupamentos de neurônios no espaço p-dimensional.

Cada ponto da imagem, ou *pixel*, $f(x_i, y_i)$, onde $x_i \in [0, x_{max}]$ e $y_i \in [0, y_{max}]$, possui um conjunto de pixels vizinhos. A conectividade entre pixels é um conceito extremamente importante principalmente quando se trata de segmentação de objetos e componentes de regiões em uma imagem. Os casos mais comuns consideram que os pixels estejam conectados aos quatro vizinhos (nas direções horizontal e vertical), ou aos oito vizinhos (os quatro anteriores mais os quatro pixels nas direções diagonais). Seja p um pixel nas coordenadas (x_i, y_i), o conjunto de pixels conectados a p no padrão de conectividade 4 são os pixels nas coordenadas (x_i+1, y_i), (x_{i-1}, y_i), (x_i, y_{i+1}) e (x_i, y_{i-1}). Este conjunto de pixels é denominado os 4 vizinhos de p, denotado por $N_4(p)$. No caso do padrão de conectividade 8, além dos pixels nas coordenadas

[2] Imagens podem possuir múltiplas bandas, como é o caso de imagens coloridas, por exemplo no padrão RGB, ou ainda como exemplo imagens de satélites.
[3] Também denominada escala de cinza.

citadas para $N_4(p)$, incluem-se os pixels nas coordenadas (x_{i+1}, y_{i+1}), (x_{i+1}, y_{i-1}), (x_{i-1}, y_{i+1}) e (x_{i-1}, y_{i-1}), formando o conjunto dos 8 vizinhos do pixel p, ou $N_8(p)$, (Gonzales e Woods, 1992). Alguns destes elementos podem estar fora dos limites físicos da imagem, $[0, x_{max}] \times [0, y_{max}]$, ocorrendo quando as coordenadas do pixel p estiverem em alguma posição da borda da imagem. No nosso caso em particular, os conjuntos dos vizinhos dos pixels situados na borda da imagem terão menos elementos do que os elementos que estão, por exemplo, em posições centrais da imagem. Por exemplo, caso p seja (0, 0), o conjunto $N_4(p)$ possuirá apenas os pixels (x_{i+1}, y_i) e (x_i, y_{i+1}). Obviamente, não há restrições a escolha do padrão de conectividade entre pixels, e pode-se escolher, de acordo com a aplicação, vários tipos de conectividade.

Em geral, as técnicas de segmentação de imagens podem ser categorizadas em duas grandes classes de métodos que são técnicas derivadas de técnicas de extração de contornos e de técnicas de crescimento de regiões[4]. No primeiro caso, são usadas as descontinuidades, i.e., alterações bruscas nos níveis de cinza da imagem, e tenta-se traçar contornos entre regiões observando o máximo gradiente, ou uma função deste, ao longo de um caminho. As formas mais comuns de obter informações de bordas são através de aproximações da primeira e da segunda derivadas, onde valores elevados indicam a existência de bordas no primeiro caso, e no segundo buscam-se mudanças de sinal em f, i.e., cruzamentos em zero. Métodos recentes de detecção de contornos são apresentados em Parker (1997).

Por outro lado, técnicas de segmentação baseadas em crescimento de regiões usam um critério de similaridade para agrupar pixels ou regiões a partir de sementes (que se denominam marcadores). A noção de conectividade de regiões R_i é bastante usada, e o objetivo é encontrar um conjunto de regiões $\boldsymbol{R}$, conhecido como partição Ω, que satisfaça critérios como:

[4] Uma terceira classe de métodos pode ser definida como os métodos que usam tanto a informação de contorno quanto de crescimento de regiões.

1. $\bigcup_{i=1}^{k} R_i = \boldsymbol{R}$;
2. $R_i \cap R_j = \varnothing, \forall i, j \in [1,k],\ i \neq j$;
3. $P(R_i)$ *é verdadeiro*, $\forall i \in [1,k]$;
4. $P(R_i \cup R_j)$ *é falso*, $\forall i, j \in [1,k],\ i \neq j$.

As condições 1 e 2 definem uma partição convencional de um conjunto, onde no critério 1 assegura-se que todo pixel deve pertencer a uma região, o que implica em uma segmentação completa, onde a união de todas as regiões $\boldsymbol{R}$ é a imagem segmentada. A condição 2 garante que nenhum pixel pertença a mais de uma região ao mesmo tempo enquanto que a condição 3 impõe que cada região R_i da partição Ω satisfaça o predicado lógico P, ou seja, cada R_i satisfaça algum critério definido pelo predicado. Finalmente a condição 4 implica que a união de duas regiões é falsa em relação ao predicado. Neste trabalho assumimos que as regiões encontradas pelo método de segmentação devem ser disjuntas.

O método mais simples de segmentar uma imagem $f(x, y)$ é através da limiarização, onde um valor escolhido entre $[f_{min}, f_{max}]$ é usado para binarizar a imagem. Por exemplo, poderíamos escolher um valor f_x que estivesse em um vale entre dois picos do histograma de f. Uma vez escolhido o valor f_x a operação de limiarização implica em comparar cada pixel de f com f_x, classificando como f_{min} caso $f < f_x$, ou f_{max} caso $f \geq f_x$. Outras técnicas podem usar vários valores limiares, definindo intervalos para limiarização, e ainda podemos usar informações locais de regiões da imagem para detectar valores adequados para os limiares. Como há compressão de informação pelo uso destas técnicas, quase sempre há alguma perda em relação à imagem original f. O objetivo é, então, minimizar as perdas para um dado critério que é, geralmente, específico para o tipo de imagem e sua forma de representação.

Em relação a *U-matrix*, o uso de técnicas simples como a limiarização em geral conduz a resultados insatisfatórios, pois geralmente este tipo de imagem possui um histograma complexo e ruidoso, não havendo, em geral, um método simples de encontrar um valor f_x adequado. Parker (1997, capítulo 3) discute vários problemas relacionados à segmentação de imagens em níveis de cinza. A seguir descreve-se o método de segmentação *watershed*, que é usado, neste trabalho, para segmentar a *U-matrix* de forma eficiente.

6.5.2.1 A transformada *watershed*

A transformada *watershed* pode ser considerada como um algoritmo híbrido, combinando tanto a abordagem de crescimento de regiões quanto detecção de contornos. Uma maneira simples de idealizar o funcionamento do *watershed* é associar a imagem f a um relevo topográfico, por exemplo, a Figura 6.20, onde se considera o nível de cinza como altitude. Definimos $B_f(m)$, uma bacia de retenção associada a um mínimo m da superfície topográfica de f, como a região na qual, caso uma gota de água caísse em qualquer ponto desta bacia, iria percorrer um caminho até atingir este ponto de mínimo. A segmentação por *watershed* vai consistir na determinação das bacias de retenção a partir do tipo das primitivas da região e do contorno, a partir dos pontos de mínimos. Assim, podemos considerá-la como um método topográfico de crescimento de regiões. Imaginando gotas de água caindo em todas as coordenadas da imagem, as k bacias de retenção captam a água, partindo de cada mínimo m^k, e à medida que o nível das bacias aumenta é possível que ocorra transbordamento da água de uma bacia para outra. Porém, isto é evitado com a construção de diques, separando as bacias retentoras e impedindo que águas de diferentes bacias sejam compartilhadas. Quando a inundação atinge o nível máximo da altura da superfície, no nosso caso f_{max}, os diques construídos separando as bacias retentoras são as linhas da *watershed* da imagem, $W(f)$, geralmente com espessura de 1 pixel, formando os contornos

das regiões segmentadas da imagem. O *watershed* gera regiões fechadas e conectadas, satisfazendo as condições 1-4 da seção 6.5.2.

O método clássico de cálculo da *watershed* faz uso de marcadores específicos, escolhidos de forma a indicar quais as bacias retentoras (mínimos locais) são importantes, e devem ser levados em consideração. Apenas as águas de bacias retentoras associadas aos mínimos descritos pelos marcadores terão rótulo, o que implica que o número de regiões finais da imagem segmentada será igual ao número de marcadores escolhidos. As Figuras 6.22-a e 6.22-b ilustram a idéia da escolha de marcadores, usando-se um corte unidimensional em uma dada imagem *f*. Note que na Figura 6.22-b apenas alguns marcadores, os relacionados às bacias retentoras mais importantes foram selecionados.

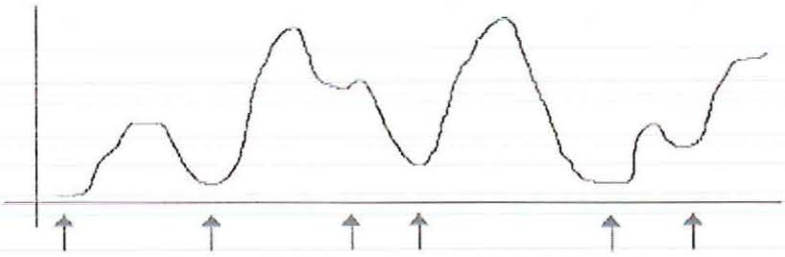

Figura 6.22-a – Marcadores para a *watershed* convencional (todos os mínimos locais).

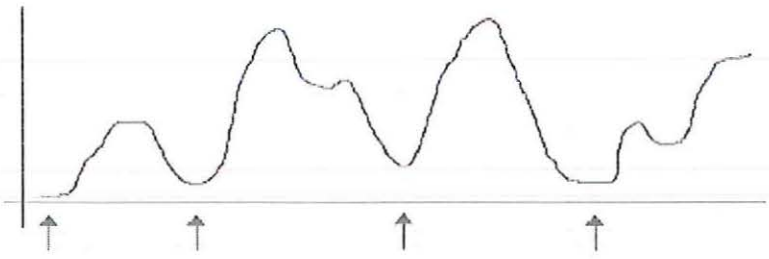

Figura 6.22-b – Marcadores para a *watershed* escolhidos manualmente (apenas alguns mínimos regionais).

Eliminando os marcadores das "bacias" indesejáveis, automaticamente diminuímos o número de partições na imagem final. A escolha adequada dos marcadores é fundamental para uma segmentação eficiente, e em nossa abordagem é feita manualmente pelo operador, a partir

da observação da imagem da *U-matrix,* sendo que escolha é feita antes de se iniciar o processo de segmentação.

Não existe uma forma geral de encontrar os marcadores, sendo, em alguns casos, de grande importância o conhecimento *a priori* do usuário acerca da imagem dos objetos a serem segmentados. Em alguns casos, é possível que o usuário, através de uma interface, escolha adequadamente as posições dos marcadores, e deixe que o algoritmo *watershed* se encarregue de detectar, de forma ótima, as bordas entre os objetos.

Um recurso que usamos para facilitar a escolha de bons marcadores para a *U-matrix,* e que gerou bons resultados, foi a filtragem da *U-matrix* removendo-se pequenos buracos na imagem. Pequenas depressões com área inferior a 3 pixels são eliminadas, suavizando muito discretamente a imagem original, resultando em uma imagem melhor para processamento, visto que a *U-matrix* possui, em geral, muitas rugosidades. O objetivo de eliminar pequenas depressões com área inferior a 3 pixels praticamente não altera, visualmente a imagem, mas facilita em muito a escolha dos limiares para os marcadores.

A Figura 6.23 ilustra os marcadores m_i, $i = 1, ..., 3$, para o caso da Figura 6.21. Aplicando-se a *watershed* sobre a imagem f, usando-se os marcadores m_i's, obtém-se as linhas de *watershed* $W(f)$ como mostrado na Figura 6.24. Note que a conectividade usada para o pixel p é $N_8(p)$.

A Figura 6.25 ilustra a sobreposição das linhas de *watershed* sobre a *U-matrix* original, para o caso bidimensional. Note que agora as bordas separando as regiões são agora todas fortes, i.e., não há mais ambigüidades, e as linhas de *watershed* representam os contornos ótimos entre as regiões, dado os marcadores.

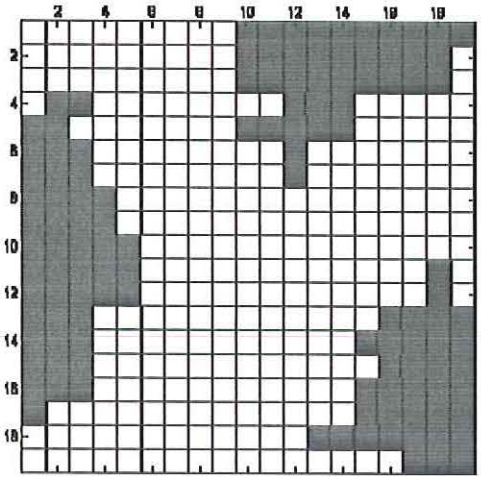

Figura 6.23 – Marcadores obtidos para a *U-matrix* da Figura 6.21 usando como limiar k=43.

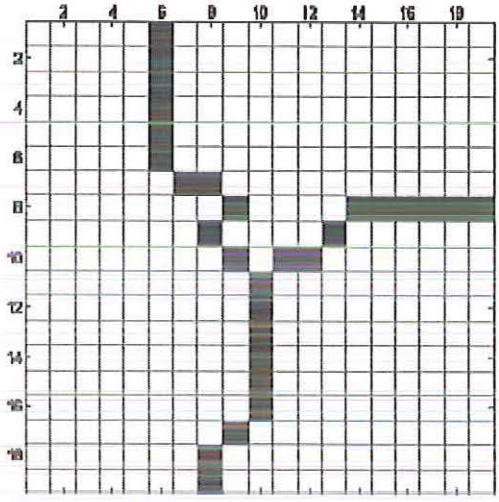

Figura 6.24 – Linhas de *watershed* obtidas da *U-matrix* da Figura 6.21.

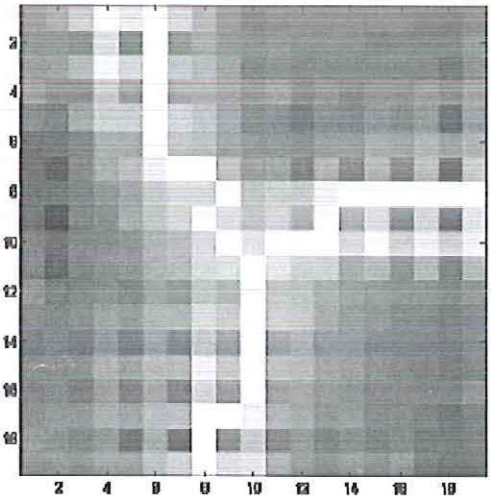

Figura 6.25 – Linhas de *watershed* sobrepostas a *U-matrix* original, Figura 6.21.

6.5.3 Rotulagem das regiões conectadas

A imagem binária resultante da aplicação do *watershed*, (ver Figura 6.24) deve ser rotulada de forma que possamos tratar os vários objetos de forma independente. Considere que a imagem binária possui os valores 0 para o fundo da imagem e 255 para os objetos conectados. Um algoritmo de *rotulação de componentes conectados* (RCC) percorre a imagem binária, por exemplo, do canto superior esquerdo ao canto inferior direito, atribuindo um código (ex. um número) a cada região ou seqüência de pixels adjacentes, de acordo com o padrão de conectividade desejado, neste caso $N_4(p)$.

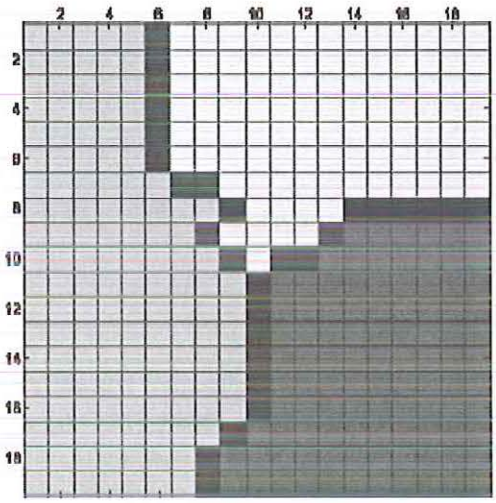

Figura 6.26 – Regiões conectadas da *U-matrix* rotuladas pelo algoritmo RCC.

Parte-se de um valor *código_atual* que é atribuído ao primeiro pixel com nível de cinza 255, i.e., o pixel faz parte de uma região em *foreground* (primeiro plano) da imagem. A este pixel denominamos semente. Todos os vizinhos da semente que possuam nível de cinza 255 são rotulados e igualmente passam a ser sementes, o que recursivamente faz preencher toda uma região conectada da imagem. Regiões diferentes recebem códigos diferentes fazendo com que caso um pixel seja detectado com valor 255 e não possua nenhum vizinho com nível de cinza diferente de 0 ou 255, o *código_atual* seja incrementado de um valor, por exemplo 1. Sempre que

detecta-se um pixel p em *foreground*, analisa-se a vizinhança $N_m(p)$, onde m dita a conectividade escolhida. Caso já houver um código atribuído a algum pixel $q \in N_m(p)$, este código é usado para rotular o pixel p.

Assim, todas as regiões e pixels adjacentes, de acordo com o padrão de conectividade escolhido, recebem o mesmo valor de código, e assim podem ser tratadas independentemente por rotinas de análise de imagem, referenciando o código como um dos parâmetros na chamada das funções. Um exemplo de rotulação é mostrado na Figura 6.26, onde foi efetuado o RCC sobre a imagem binária apresentada na Figura 6.23.

Toda análise e segmentação de um mapa de tamanho N x M é feita inicialmente sobre a *U-matrix*, e posteriormente as informações associadas aos pixels são associadas aos neurônios. Assim, obtidos os rótulos pelo RCC, eles são copiados para os neurônios associados a cada pixel da *U-matrix*. A Figura 6.27 ilustra o resultado da transferência dos rótulos da *U-matrix* para o SOM.

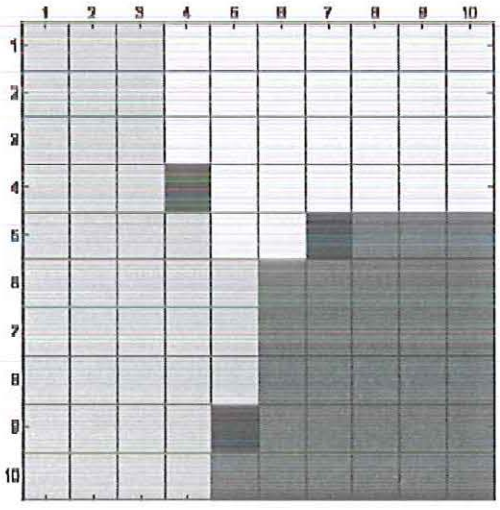

Figura 6.27 – Rotulagem de neurônios do SOM 10 x 10 pela cópia dos códigos da *U-matrix* rotulada (Figura 6.26).

Note que três neurônios permaneceram sem código, por exemplo, o neurônio (4,4). Isto ocorre geralmente quando neurônios inativos cujos pixels

associados da *U-matrix* fazem parte da linha de watershed. Podemos deixar os neurônios não rotulados de lado, fixando-nos apenas nos neurônios rotulados. Mas caso um padrão $\boldsymbol{x}$ seja mapeado num neurônio não rotulado, poderíamos, neste caso, rotulá-lo usando o método vizinho mais próximo, ou k-vizinhos mais próximos. Isto poderia ser feito, por exemplo, buscando o segundo neurônio vencedor para o padrão $\boldsymbol{x}$, e caso este também estivesse não rotulado, o terceiro, e assim por diante. A classe, ou código atribuído pelo algoritmo RCC, do neurônio rotulado encontrado, nesta seqüência, é usado para rotular o padrão $\boldsymbol{x}$, a Figura 6.28 ilustra o mapa totalmente rotulado usando o método vizinho mais próximo.

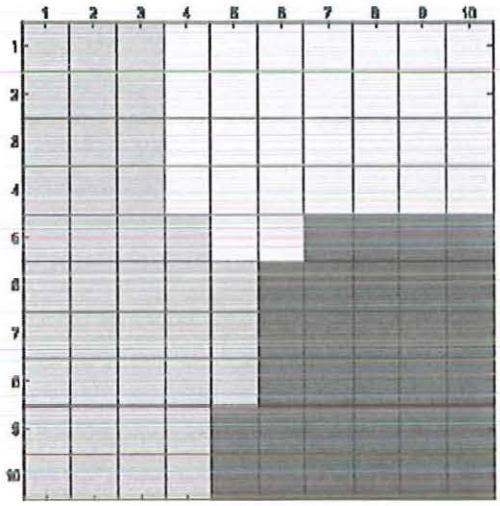

Figura 6.28 – Mapa 10 x 10 totalmente rotulado usando o método vizinhos mais próximos para classificar os pixels não rotulados da Figura 6.27.

A Figura 6.29 ilustra o mapeamento dos padrões no mapa 10 × 10. A forma convencional de rotular um mapa treinado é fazer com que cada padrão seja mapeado no SOM, i.e., seja apresentado e detectado o neurônio vencedor. A classe atribuída ao neurônio é a classe dos padrões mais freqüentes que são mapeados nele. Desta forma, usa-se o SOM apenas para fazer uma projeção dos dados de um espaço p-dimensional para uma grade bidimensional, e o processo de rotulação usa informação *a priori*, o que em muitos casos não está disponível. Por exemplo, o neurônio (1,1), que está no

canto superior esquerdo do mapa, foi rotulado como pertencente à classe 2. Note que nem todos os neurônios receberam rótulos, o que pode ser visto na Figura 6.10, onde o histograma de vencedores para este problema é apresentado. Alguns neurônios não estão mapeando nenhum padrão, e desta forma, no método convencional não há, em princípio, como classificá-los. Outro problema freqüente é o conflito, o que ocorre quando dois padrões de classes distintas são mapeadas no mesmo neurônio. Geralmente ocorre quando as classes possuem algum nível de sobreposição, quando os dados estão mal condicionados, ou quando escolhemos de forma errada os atributos usados no processo. Pode-se, quando possível, buscar encontrar atributos adicionais que habilitem a separabilidade das classes.

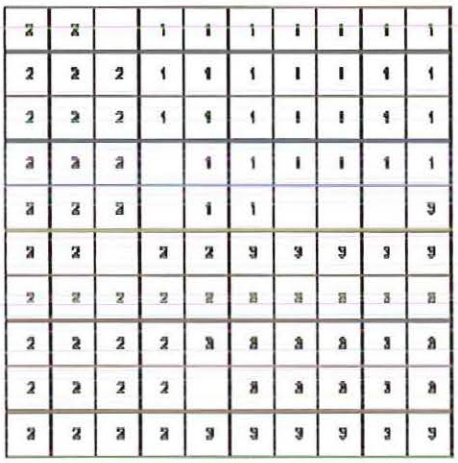

Figura 6.29 – Mapeamento dos padrões no mapa 10 x 10 usando a informação *a priori* das classes dos padrões.

De posse da Figura 6.29, pesquisadores efetuam manualmente uma separação de regiões, em geral desconsiderando os neurônios não rotulados. Vê-se que o número de agrupamentos, no método tradicional, deve ser conhecido a priori, caso contrário, não há como segmentar manualmente o mapa. Exemplos de rotulação manual são apresentados em Kohonen (1997a).

O método que adotamos efetuou a segmentação e rotulação do SOM (ver Figura 6.28) usando apenas os padrões. Nenhuma informação de classe foi usada. A Figura 6.30 ilustra a sobreposição da Figura 6.29 em 6.28. Vemos

que, neste problema, a segmentação foi perfeita, i.e., nenhum padrão de uma classe foi mapeado em uma outra classe. Outra informação importante é que o método determinou o número de agrupamentos nos dados, 3, sem auxílio de informações privilegiadas, como ocorre no caso convencional.

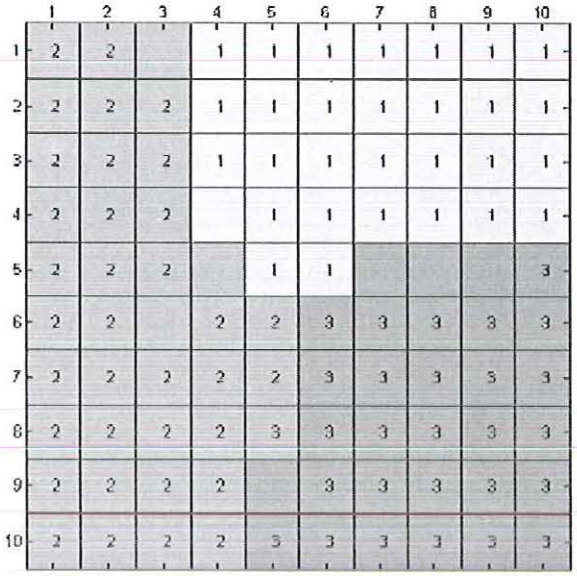

Figura 6.30 – Mapeamento dos padrões no mapa 10 x 10, usando a informação das classes dos padrões, sobreposto à partição do mapa obtida usando apenas os padrões.

Cada agrupamento agora é descrito por um conjunto de neurônios, cada neurônio um vetor no espaço p-dimensional. A Figura 6.31 ilustra isto, onde cada neurônio recebeu um código de acordo com o agrupamento que pertence. Note que todos os neurônios foram representados de forma similar em relação ao tamanho, mudando apenas o nível de cinza, que corresponde ao código do agrupamento. A Figura 6.32 usa o histograma de vencimentos, i.e., quantos padrões cada neurônio está mapeando para representar o tamanho do neurônio na grade. Os números sobre os neurônios (1, 2 e 3) são os códigos das classes descobertas durante o processo de rotulação, i.e., RCC. Assim, a classe de padrões 1, que é a que está mais a esquerda da Figura 6.30 é representada pelo agrupamento 2. A classe de padrões 2 é representada pelo agrupamento rotulado como 1, e na classe de padrões 3, o código atribuído ao agrupamento pelo método RCC foi 3. Não há nenhuma preocupação em

coincidência do rótulo do agrupamento com o rótulo da classe dos padrões, mesmo porque não foi usada em nenhuma fase informações da classe, e os códigos atribuídos pelo método RCC seguem uma numeração automática, a medida que vai encontrando regiões não rotuladas na imagem. O importante é que o método descobriu a existência das classes, com número certo, e gerou um agrupamento de neurônios através da segmentação e rotulação de forma que cada agrupamento de neurônios corresponde a um modelo dos dados, que pode ser usado, inclusive para classificar novos padrões não usados na fase de treinamento.

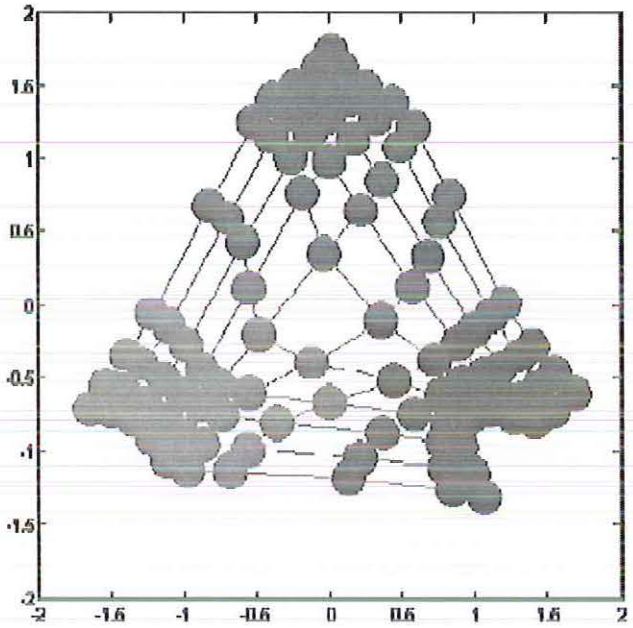

Figura 6.31 – Grade do mapa 10 x 10 rotulado. Na figura todos os neurônios foram representados com o mesmo tamanho, diferenciando apenas o nível de cinza, que está relacionado ao agrupamento detectado.

Uma vez dispondo do SOM rotulado, como apresentado na Figura 6.30, os dados são classificados de acordo com a classe do agrupamento de neurônios onde se encontra o neurônio o que está mapeando. A Figura 6.33 ilustra a classificação dos dados obtida através deste método. Partindo apenas do conjunto de dados, o processo de classificação pode ser pensado como um método que adiciona uma coluna à matriz de dados, onde esta coluna é exatamente a classe do padrão.

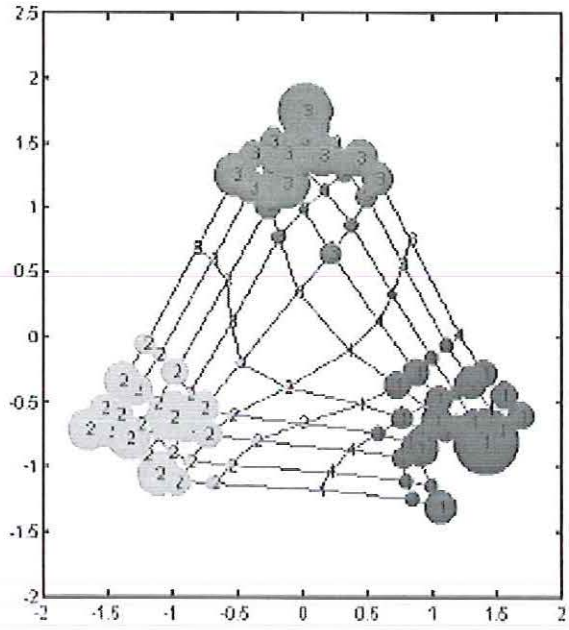

Figura 6.32 – Grade do mapa 10 x 10 rotulado, usando a informação de número de padrões mapeados em cada neurônio para representar o tamanho da grade.

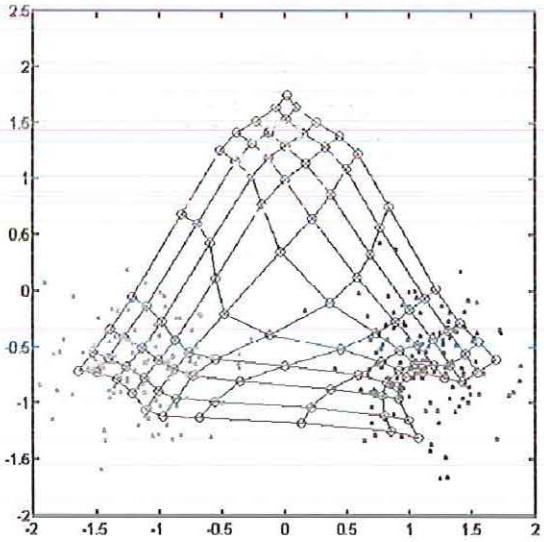

Figura 6.33 – Classificação dos padrões usando a classe dos neurônios vencedores.

6.6 Sumário

Este capítulo descreveu a ferramenta básica que iremos explorar para detecção dos agrupamentos de MUAPs, o SOM. Discutimos aspectos do treinamento e seus parâmetros, e uma forma de interpretação de como é o processo de quantização efetuado após o treinamento. Em seguida, destacamos que a melhor alternativa atual no treinamento é conjunção de inicialização linear e o uso do algoritmo em lote. O primeiro fator implica em começar o treinamento em um estágio relativamente avançado de ordenação em relação inicialização convencional, que é a aleatória. O algoritmo em lote além de ser mais rápido é insensível à ordem de apresentação dos dados, o que não ocorre no algoritmo convencional (seqüencial). Além disto, usando o algoritmo em lote não temos a preocupação da escolha da taxa de aprendizado, $\alpha(t)$, a qual pode inclusive ser fixada em um valor pequeno constante, ex. 0.05.

Descrevemos a formulação matemática da *U-matrix* e propusemos um método de segmentação e rotulagem automática das regiões de neurônios, as quais formam modelos de representação distribuída dos protótipos. Um exemplo foi usado, mostrando a eficiência do método detectando agrupamentos sem informações *a priori* da geometria das classes, ou do número destas. A estrutura se adapta ao problema, e não vice-versa, como ocorre nos algoritmos convencionais como o *k-means*. Além disto, uma breve interpretação do processo de agrupamento dos neurônios foi abordada assim como maneiras de incorporar a informação de H (o histograma de vencimentos de padrões pelos neurônios) no cálculo da *U-matrix*. Nota-se que apenas agrupamentos conexos são obtidos por este método. Os algoritmos descritos neste capítulo foram executados em ambiente Matlab 6.1, utilizando o pacote para Matlab Somtoolbox 2.0 disponível em http://www.cis.hut.fi/projects/somtoolbox, o qual implementa o algoritmo SOM e diversas funções úteis. Usou-se também o pacote SDC Morphology Toolbox disponível sob licença em http://www.mmorph.com, que implementa

em Matlab várias funções morfológicas para análise de imagens e processamento de sinais incluindo a transformada watershed.

CAPÍTULO 7

RESULTADOS EXPERIMENTAIS E DISCUSSÃO

7.1 Resultados da decomposição

Após a obtenção da matriz de dados contendo os MUAPs candidatos como mostrado no capítulo 5, iniciamos a fase de classificação dos candidatos. Nos ensaios foi usado um mapa SOM com grade 19x19 e vizinhança hexagonal. A alternativa escolhida para o treinamento do mapa SOM foi a conjunção da inicialização linear com o uso do algoritmo em lote, conforme discutido no capítulo 6. O primeiro fator implica em começar o treinamento em um estágio relativamente avançado de ordenação em relação inicialização convencional, que é a aleatória. O algoritmo em lote além de ser mais rápido é insensível à ordem de apresentação dos dados, o que não ocorre no algoritmo convencional (seqüencial). Além disto, usando o algoritmo em lote não temos a preocupação da escolha da taxa de aprendizado, $\alpha(t)$, a qual pode inclusive ser fixada em um valor pequeno constante, sendo que em nossos ensaios ela ficou fixa em 0.05.

A matriz de dados usada nos ensaios realizados neste capítulo e no treinamento do SOM foi gerada a partir de um segmento de sinal EMG com 10 segundos de duração (Figura 7.1), adquirido sob contração isométrica em torno de 5 % da CVM, extraído do grupo normal (NOR), o limiar usado pelo algoritmo de detecção dos picos de MUAPs ficou em torno de 25%, conforme o procedimento descrito no capítulo 5. O conjunto de treinamento foi constituído de 360 MUAPs candidatos, sendo que cada MUAP candidato foi

representado por um vetor de 128 pontos, equivalente a 12.8 ms de duração, assim sendo a dimensão da matriz de dados foi de 360×128.

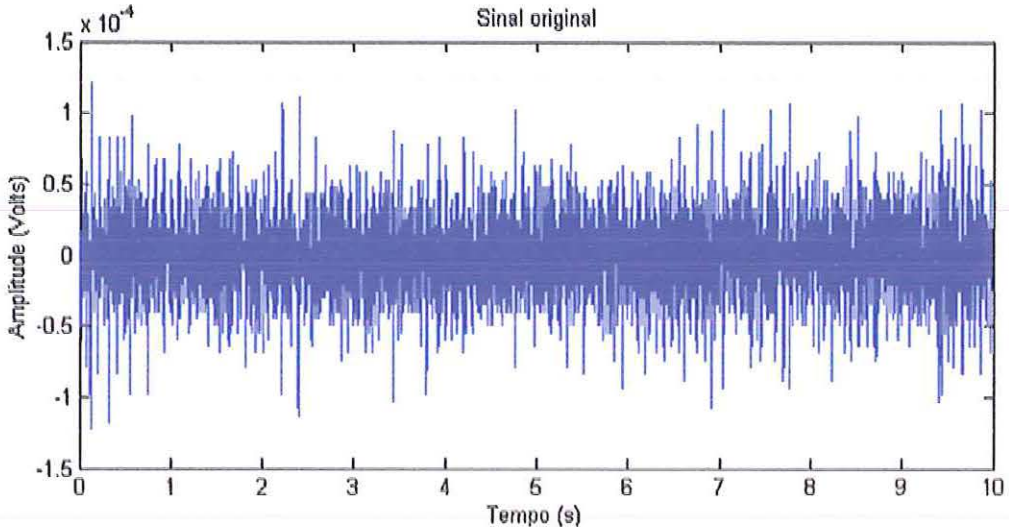

Figura 7.1 – Segmento de sinal EMG extraído do grupo NOR, adquirido em contração isométrica a 5% da CVM usado para geração da matriz de dados usada nos ensaios.

Completado o processo de treinamento do SOM, iniciou-se o processo de classificação adotando o método proposto na seção 7.5, este processamento categorizou os candidatos em vários *clusters*. Durante o processo de classificação, *clusters* com menos de três candidatos foram descartados, pois geralmente correspondem a MUAPs compostos por superposições ou a formas corrompidas por artefatos. Um algoritmo para resolução de superposição poderia ser desenvolvido para solução desses casos, mas encareceria o processo, por isso optamos por não tentar resolvê-los. Mais do que indexar todos MUAPs detectados é muito importante que os resultados do agrupamento sejam precisos e MUAPs superpostos sejam ignorados. Como tal, o algoritmo de agrupamento não necessita considerar todos MUAPs detectados nem classificar todos MUAPs considerados. Até mesmo porque, durante as fases posteriores da decomposição é mais fácil fundir dois trens em um, que dividir um trem em dois, portanto é preferível subestimar o número de MUAPTs.

O esquema de classificação que adotamos foi baseado na informação de forma de onda dos MUAPs. Todavia, seria interessante a utilização conjunta da informação temporal dos MUAPs com a informação de forma, o que aumentaria sobremaneira a eficácia do processo de classificação. No entanto tal implementação no SOM seria muito complexa, assim sendo adotamos a classificação baseada principalmente na morfologia dos MUAPs, tendo a informação temporal apenas como um complemento. A idéia é que quando um candidato é classificado dentro de um *cluster* (BMU), a informação temporal seja usada para verificar esta classificação, se a verificação mostra que ele é evidentemente inválido, o BMU para este candidato é abandonado. O problema é como escolher uma regra de verificação que seja simples o bastante para evitar a complexa análise probabilística da informação temporal na fase de classificação. Adotamos um critério simples que foi:

$$\left|t - t_l\right| > t_i \tag{7.1}$$

Na equação (7.1) $|t - t_l|$ é o intervalo entre dois picos consecutivos do mesmo trem de MUAP, onde t é o tempo de disparo do candidato atual e t_l é o tempo de disparo do candidato subseqüente classificado dentro do mesmo *cluster*, e t_i é o *período refratário relativo* dos nervos motores. Se a classificação é aceita como válida, um registro é gerado para armazenar os tempos de disparo dos candidatos classificados naquele *cluster* formando assim um MUAPT válido.

A Figura 7.2 mostra os resultados da decomposição para o EMG da Figura 7.1, de onde puderam ser identificados quatro MUAPTs contribuindo significantemente para a composição do sinal. Sendo que o número total de MUAPs identificados em cada MUAPT foi: MUAPT1=110; MUAPT2 = 88; MUAPT3 = 39; MUAPT4 = 86.

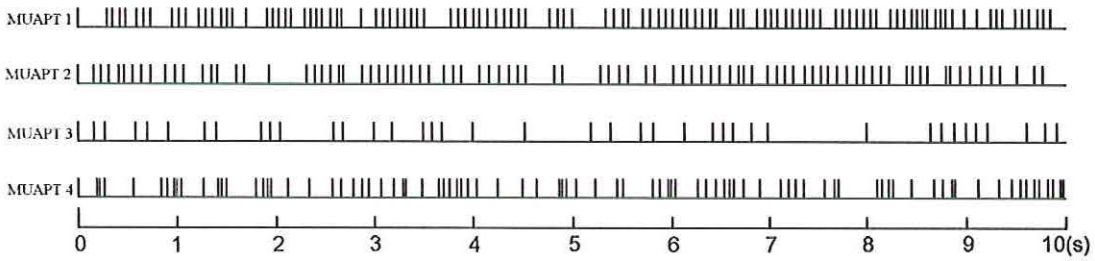

Figura 7.2 – Padrões de disparo instantâneo das UMs identificadas no sinal da Figura 7.1. Os MUAPs agrupados pelo algoritmo de classificação, após a etapa de checagem do período refratário, são organizados em função de seus tempos de disparos dispostos em ordem crescente, compondo assim os MUAPTs válidos.

Os histogramas mostrando a distribuição observada dos IPIs para os quatros MUAPTs identificados no sinal são apresentados na Figura 7.3.

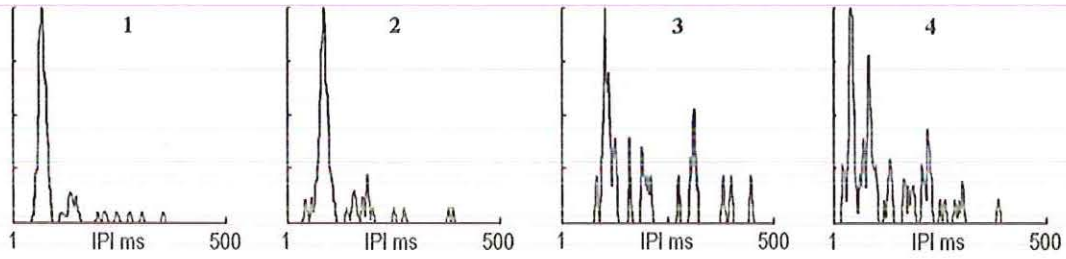

Figura 7.3 – Histograma mostrando a distribuição observada dos IPIs para os quatros trens de MUAPs resultantes da decomposição do sinal EMG da Figura 7.1.

Concluídas as verificações sobre os trens de MUAPs, a forma de onda do MUAP representativo de cada MUAPT pode ser construída pela média das formas de onda de todos os MUAPs pertencentes ao trem, conforme Figura 7.4, que mostra os MUAPs protótipos para as UMs identificadas, observa-se que as formas de onda extraídas são normais, estando de acordo com a teoria do volume condutor (Rosenfalck, 1964).

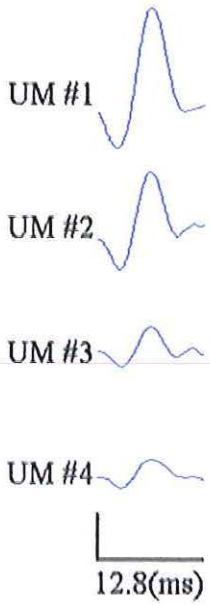

Figura 7.4 – Formas de ondas dos MUAPs protótipos (amplitude normalizada) para os quatro MUAPTs decompostos, estimadas pela média das formas de onda de todos os picos pertencentes aos seus respectivos trens (MUAPTs).

Adicionalmente, a Figura 7.5 ilustra um segmento do sinal puro e do sinal filtrado com os picos identificados.

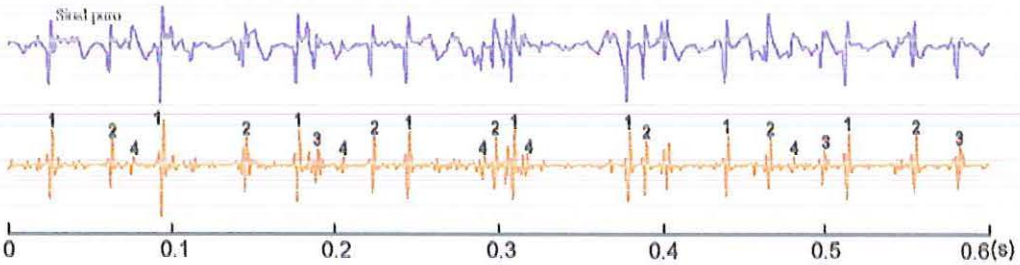

Figura 7.5 – Segmento do sinal EMG original e do sinal EMG filtrado com os picos identificados.

7.2 Avaliação da decomposição

Os MUAPTs válidos foram, além disso, verificados por uma checagem de regularidade dos disparos baseada na análise do Intervalo entre Pulsos (IPI), para avaliar a qualidade da decomposição. Sendo que a idéia básica por trás dessa análise reside no fato de que um trem de impulsos

oriundo de um neurônio isolado deve ter um IPI médio estável[1], há uma variância neste intervalo de disparo a disparo. "*Um neurônio isolado pode então ser modelado como produzindo IPIs que obedecem a uma distribuição Gaussiana com média μ, e desvio padrão σ*" (Gath, 1974). A variabilidade é normalmente expressada como a razão entre o desvio padrão e o IPI médio, e é referenciada como o *coeficiente de variação*, $CV = \sigma/\mu$.

Devemos considerar também que o conjunto de dados provido é incompleto. Quando o sinal mioelétrico é gravado, ele é inicialmente decomposto em seus potenciais de ação individuais. Os sinais decompostos são então agrupados, usando características físicas, em classes representando fontes de neurônios motores isolados, o amontoado de mais de um neurônio disparando dentro de uma classe é o que estamos tentando detectar nesse problema. Os passos do algoritmo de agrupamento, contudo, não são totalmente bem-sucedidos devido a superposições de sinal não resolvidas e, menos freqüentemente, detecções perdidas pelo eletrodo. Alguns disparos de potenciais de ação são por essas razões perdidos, resultando em um conjunto de dados incompleto. Isto freqüentemente se manifesta nos dados como um IPI muito extenso. Em nossa análise de IPI assumiremos que os padrões de disparos de dois neurônios diferentes são independentes um do outro, de acordo com Gath, (1974).

A partir do padrão de disparo de cada UM identificada, são estimados os parâmetros de disparos (intervalo médio de disparo (μ), desvio padrão (σ), coeficiente de variação (*CV*) e taxa de identificação (**ID**), descritos na seção 5.4.2). Em seguida gera-se uma distribuição Gaussiana de IPIs randômicos com esses parâmetros, tal que os IPIs tenham a média e o desvio padrão desejado. Além disso, dado um valor nominal para a porcentagem de

[1] Em algumas situações de pesquisa o uso dos histogramas de IPIs não será útil por assumir padrões de disparo pseudo-regulares, o que pode não ser apropriado.

dados perdidos, uma rotina remove probabilisticamente dos dados de entrada alguns pontos simulando o que ocorre com um EMG real. Um histograma do IPI foi construído relacionando o número de ocorrências (ou a probabilidade de ocorrência) com o IPI, conforme mostra a Figura 7.6, que compara o histograma real de IPI do MUAPT #1 com o histograma estimado. Para dados de IPIs reais, os parâmetros verdadeiros são desconhecidos, mas uma avaliação qualitativa pode ser feita a partir da observação do ajuste da função densidade de probabilidade estimada à função computada do histograma de um IPI real. A Figura 7.6 mostra que as funções de probabilidade estimada e observada para o MUAPT #1 se ajustam razoavelmente bem, mostrando que a decomposição foi bem feita.

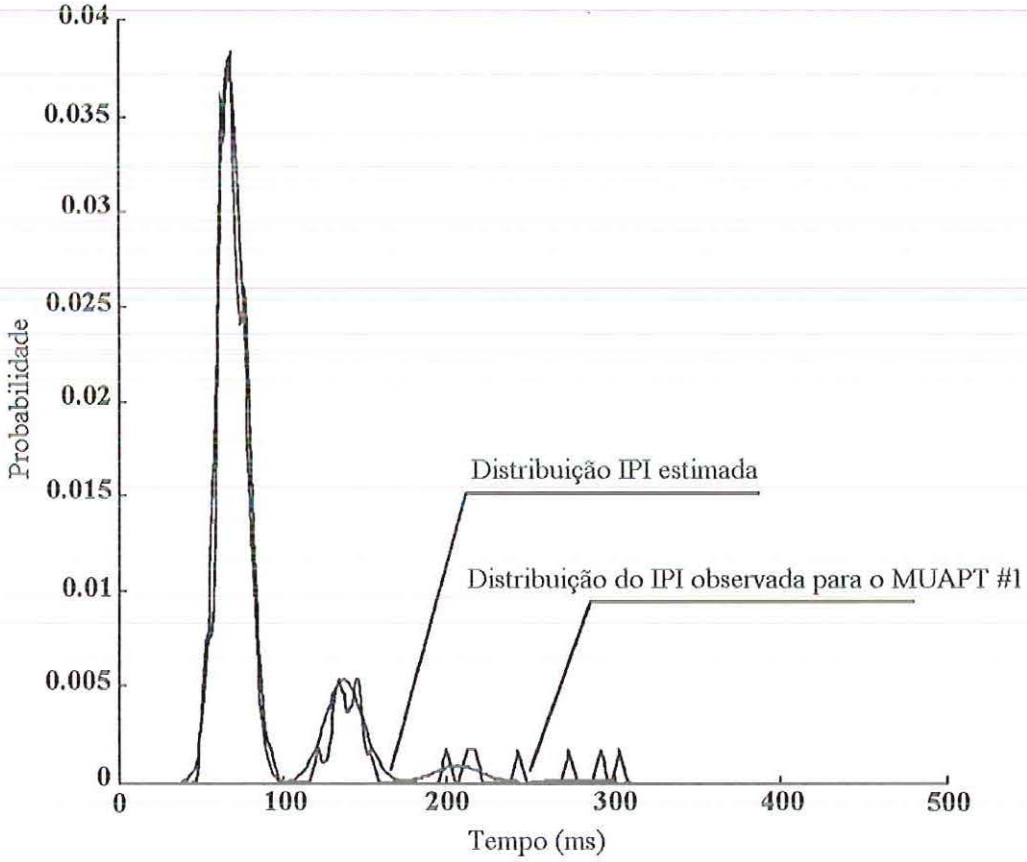

Figura 7.6 – Função densidade de probabilidade do IPI estimada versus a função observada do MUAPT #1. (taxa de identificação: ID = 0.70; IPI médio: · μ = 62.8 ms; desvio padrão: · σ = 9.4 ms, coeficiente de variação: CV = 0.15, taxa de disparo médio = 15,9 Hz).

7.2.1 Detecção de erros de classificação

Um processo de refinamento adicional usando uma rotina de análise de IPI foi desenvolvido para detectar falsas classificações. A abordagem que usamos envolve a examinação dos valores de IPI de um histograma para determinar a proporção do IPI que é anormalmente curta. Este processo, em princípio, assemelha-se ao usado por Hassoun et al (1994) e McGill et al (1997). Um grande número de intervalos curtos vai indicar que dois trens foram impropriamente fundidos. Se dois trens de pulsos de dois neurônios diferentes são impropriamente fundidos, há uma probabilidade muito alta para IPIs muito curtos. Por exemplo, suponha que um trem com IPI médio, $\mu = 60$ ms seja fundido a outro com $\mu = 100$ ms. Se um histograma de IPIs é feito, uma fração deles apareceria na faixa de 0 – 20 milisegundos, correspondendo a neurônios disparando um após o outro em intervalo de tempo muito curto. Se os trens não estivessem fundidos, porém, seria altamente improvável ver IPIs curtos, dependendo do valor do coeficiente de variação, 20 ms fica entre 3 e 6 desvios padrão distante da média de 60 ms. Para o trem de pulsos com $\mu = 100$ ms, IPIs curtos são ainda mais improváveis. Abaixo ilustramos esses casos.

Ainda que a abordagem do histograma IPI seja razoavelmente intuitiva para detectar falsas classificações, ela não é suficiente para citar esta intuição como solução do problema. Antes deveríamos ter um critério específico ou métrica que permita a uma rotina computacional tomar decisões quanto as falsas classificações. Uma sugestão imediata para tal critério poderia ser contar o número de IPIs que ocorrem abaixo do valor médio para o trem, e se ele estiver acima de um certo limiar, chamemos isto de uma falsa classificação. Esta é uma apelação intuitiva que um observador humano poderia fazer, mas infelizmente não daria certo, porque como o coeficiente de variação, a proporção de dados perdidos, e o número total de pontos varia, fica difícil (ou impossível) fixar um único valor de limiar. Naturalmente, se nós pudéssemos predeterminar estes parâmetros, poderia ser possível responder

inteligentemente o seu valor, contudo a premissa básica do problema é que nós não sabemos os valores destes parâmetros. Então, deveríamos procurar por uma métrica "robusta" que fosse relativamente insensível a mudanças nos parâmetros entre os conjuntos de dados da amostra, mas altamente sensível à presença de trens de pulsos fundidos.

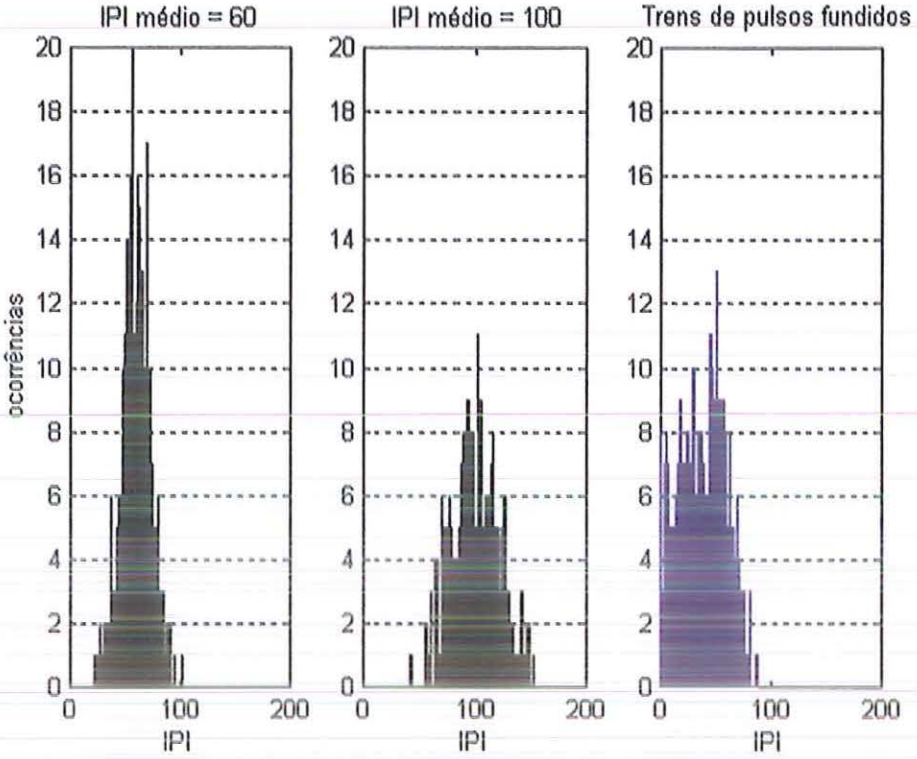

Figura 7.7 – Histograma de dois trens de pulsos diferentes e o histograma resultante de suas fusões (obtido por simulação).

Tal métrica poderia ser o menor coeficiente de variação. Este é simplesmente o coeficiente de variação para todos os dados que ficam abaixo da média. Para trens não fundidos, este valor seria pequeno, porque a maioria dos dados fica próximo da média. Para trens fundidos, contudo, este valor seria notadamente maior por causa da dispersão de dados abaixo da média i.e., IPIs curtos. O menor CV é relativamente insensível a mudanças no número de pontos de dados e na proporção de dados perdidos. E, como o coeficiente de variação global varia, o mais baixo coeficiente de variação ainda manteria uma

diferença significativa entre valores computados para trens fundidos e não fundidos. Estas alegações, naturalmente, serão verificadas através de testes. Existem outras boas métricas, tais como os momentos das áreas ou a razão das integrais acima e abaixo da média, mas só o menor *CV* será usado por enquanto, desde que é relativamente simples para computar e visualizar.

Como mencionado antes, o fato de uma proporção dos dados ser perdida torna o problema ligeiramente mais complicado. Quando a decomposição e o agrupamento são realizados no sinal mioelétrico adquirido, acontece às vezes de vários neurônios dispararem quase simultaneamente, então, alguns potenciais de ação são perdidos devido a superposições não resolvidas. Um histograma de IPI para um único neurônio, nesse caso, deve resultar então em dados que estejam bem acima do verdadeiro valor médio. Por exemplo, consideremos um neurônio disparando com IPI médio $\mu = 60$ ms, e 30% de dados perdidos. O pico do histograma ocorre próximo de 60 ms, contudo, sob o efeito dos dados perdidos, máximos locais de magnitude decrescente ocorrem também próximos dos múltiplos inteiros de 60 ms, vide Figura 7.8. Este efeito de "*aliasing*" da média pode ser compreendido percebendo que se um ponto de dado é omitido, o IPI mais provável corresponde ao dobro do IPI médio sem pontos perdidos. Além disso, o desvio padrão local para este pico será aproximadamente o dobro do valor calculado usando o coeficiente de variação.

Assim, se a média é computada usando o conjunto completo de dados dos valores de IPIs, a resposta seria maior que média verdadeira para o neurônio, quando encontrado o menor coeficiente de variação. Grandes IPIs correspondendo a disparos de neurônios omitidos, deslocariam o valor da média para um valor maior que o correto. No exemplo da Figura 7.8 abaixo isto fica claro.

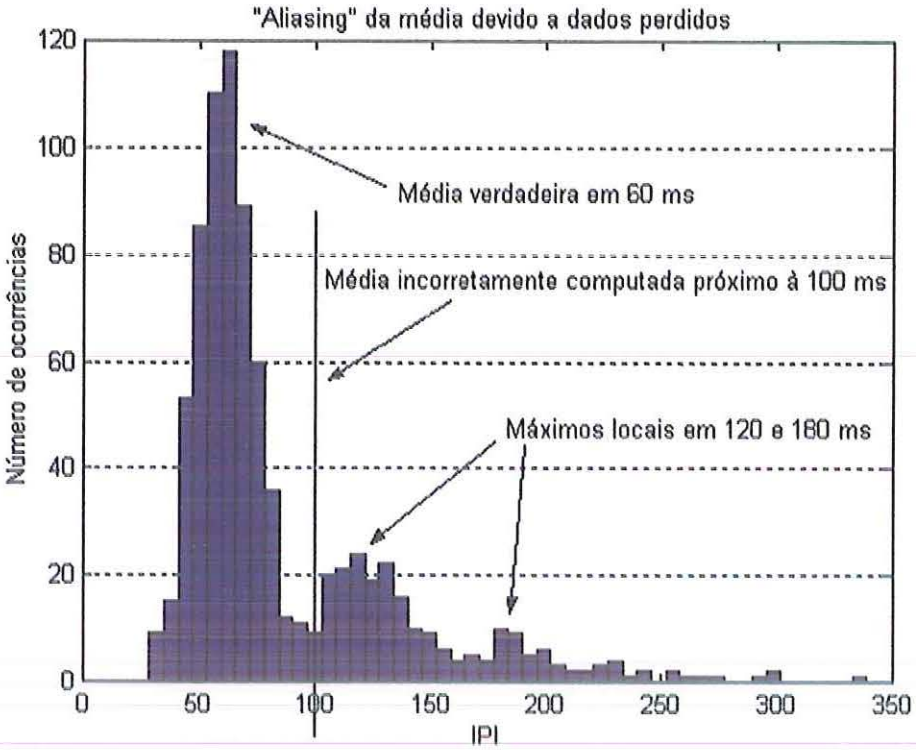

Figura 7.8 – "*Aliasing*" da média devido a dados perdidos (obtido por simulação).

O que desejamos, naturalmente, é o verdadeiro IPI médio, e não este valor médio distorcido. Para achar a média verdadeira, então, os grandes valores de IPIs correspondendo a disparos perdidos devem ser desprezados nos cálculos. Um algoritmo foi desenvolvido para fazer exatamente isto. Abaixo temos uma visão geral deste algoritmo:

1. Compute a média e o desvio padrão usando o conjunto de dados completo;
2. Usando somente os dados que estão dentro de 1.5 desvios padrão desta média, recalcule a média e o desvio padrão;
3. Repita o passo 2 até a convergência.

Sabemos que este algoritmo irá convergir aproximadamente para o valor médio verdadeiro porque, pelo menos para as primeiras iterações, o valor médio computado irá decrescer monotônicamente. Isto se deve ao fato

de haver mais dados abaixo da média do que acima. Esta diminuição continuará até que o valor médio esteja próximo do valor verdadeiro, ponto no qual os efeitos de amostragem randômica e dados perdidos começam a surgir. O resultado é uma estimativa bem razoável do valor médio verdadeiro. O fator 1.5 foi determinado experimentalmente. Foi observado que para fatores em torno e acima de 2.0 estes divergiam ou convergiam após muitas interações, isto porque a janela não admitia ser estreitada. Para um fator de 1.0 foi observado um rápido estreitamento da janela, que freqüentemente conduzia a um dos valores médios próximos de um dos múltiplos da média verdadeira. O fator 1.5, contudo, produziu estimativas da média que estavam, invariavelmente, em ótima concordância com as estimativas visuais (isto é o melhor que pode ser feito porque, pois quando dados são perdidos a média verdadeira não existe "verdadeiramente").

O problema de estimação e checagem de erros de variância de uma média, dado um conjunto incompleto de dados, é bem interessante. Existem alguns métodos populares voltados para esse fim como o *"bootstrapping"*. Porém, estes métodos não assumem nenhum conhecimento anterior sobre os dados. O algoritmo descrito acima é preferível porque leva em conta o comportamento dos dados, e assim retorna valores mais significantes para a média.

Uma vez que encontramos o valor verdadeiro do IPI médio, a computação do menor *CV* é extremamente fácil. Simplesmente tomamos todos os valores IPIs que estão abaixo da média verdadeira, e computamos sua média e desvio padrão. A razão entre esses dois últimos é a métrica desejada, o menor *CV*.

Tudo que restou do problema, então, foi computar o menor *CV* para vários trens fundidos e não fundidos, e discernir um valor limite discriminante. Que se resumiu em *determinar um valor limiar para o menor CV acima do*

qual pode ser concluído haver uma falsa classificação. O comportamento da métrica sob mudança de vários parâmetros foi considerado na escolha deste valor discriminante para o menor *CV*. Os parâmetros variados foram o *CV*, a porcentagem de dados perdidos, e o período de amostragem (que afeta diretamente a quantidade de dados disponíveis), de dois trens não fundidos. A métrica também foi testada sob vários valores para a razão entre IPIs médios de dois trens não fundidos. *Para cada parâmetro, são usados valores típicos, bem como valores fora da gama típica, isto foi feito para assegurar que o algoritmo manipula corretamente valores não usuais de cada parâmetro, que podem ser um indicativo de uma desordem neuromuscular.* Afinal de contas, desejamos poder distinguir entre patologias e falsas classificações. Se essa distinção fosse obscurecida, então esta métrica seria de valor limitado.

7.2.2 Testes para avaliação da métrica usada

Em cada teste para um conjunto de parâmetros, o menor *CV* foi computado para cada uma das combinações permitidas de IPIs médios não fundidos. Valores típicos para o IPI médio de um neurônio saudável variam de 40 ms a 100 ms, para este problema, foram usados valores entre 20 ms e 200 ms, variando em incrementos de 5 ms. Conseqüentemente, para cada conjunto de parâmetros testado, cada combinação de par de valores entre 20 ms e 200 ms é testada. Em seguida a métrica é computada para o caso quando estes mesmos dois trens são fundidos (em azul para todos os gráficos a seguir), um grande aumento entre os trens não fundidos e fundidos é o que se espera.

Como mencionado antes, neurônios isolados foram simulados como um padrão de disparo com um IPI médio, μ, e um desvio padrão, σ. Dados perdidos foram simulados usando a porcentagem como uma probabilidade para a qual qualquer um dos pontos de dados teria de ser excluído. Deste modo, uma proporção dos pontos de dados foi randomicamente removido de

cada conjunto de dados. Nos gráficos mostrados a seguir, os valores do menor *CV* para dois trens não fundidos são mostrados em vermelho, e os valores resultantes da fusão dos dois trens (i.e., falsas classificações) são mostrados em azul.

Para um paciente saudável, os valores típicos do coeficiente de variação para um neurônio isolado se situam entre 0.1 a 0.15. Exceto em condições patológicas, é raro se ver neurônios com coeficiente de variação maior que 0.20. Para propósito de teste usaremos então valores entre 0.05 e 0.30. Um valor padrão de 0.20 será usado durante os ensaios quando o *CV* for mantido constante.

7.2.2.1 Teste do coeficiente de variação

A variação do menor *CV* versus variação no *CV* para trens não fundidos é mostrada na Figura 7.9. Os dados mostram que enquanto o menor *CV* para trens não fundidos apresenta uma tendência crescente à medida que o *CV* para trens não fundidos é aumentado, o valor para trens fundidos parece não ser afetado. Isto faz sentido intuitivamente. Pode ser visto da Figura 7.9 que os valores do menor *CV* entre 0.25 e 0.30 aproximadamente, seriam escolhas adequadas para o valor limite. Para maximizar a gama de valores *CV* para trens não fundidos, acima dos quais o discriminante seria válido, é melhor escolher um valor para o menor *CV* perto de 0.30.

Pode ser visto claramente, que este valor não produziria, necessariamente, resultados corretos para valores do CV para trens não fundidos acima de 0.3. No entanto, para a grande maioria dos exemplos, o valor do discriminante (i.e. o menor CV) seria muito maior ou muito menor do que o valor limite de 0.3, então a métrica ainda poderia ser usada contanto que valores entre, digamos, 0.25 e 0.35 sejam interpretados como informação insuficiente.

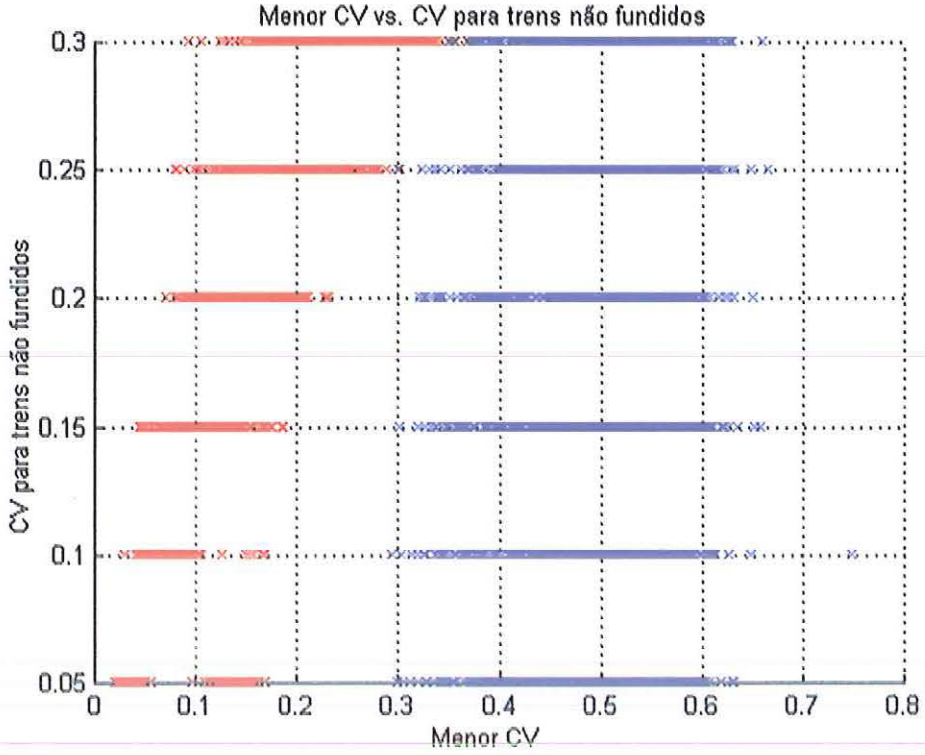

Figura 7.9 – Variação do menor *CV* versus variação no *CV* para trens não fundidos. Valores do menor *CV* para dois trens não fundidos são mostrados em vermelho, e os valores resultantes da fusão dos dois trens (i.e., falsas classificações) são mostrados em azul.

7.2.2.2 Testes de dados perdidos

A decomposição do sinal EMG e o processo de clustering, tipicamente, identificam entre 60 – 90% dos disparos de um dado neurônio. Assim, os valores da porcentagem de dados que normalmente são perdidos ficam em torno de 10 – 40%. Valores entre 0% e 70% foram testados neste ensaio. Um valor padrão de 40% (ou 0.4) é usado durante os ensaios quando a porcentagem é mantida constante. As variações do menor CV com incrementos na proporção de dados perdidos são mostradas na Figura 7.10.

Os dados mostram que o valor da métrica para trens fundidos relativamente não é afetado pelo incremento na proporção de dados perdidos. Para trens não fundidos, contudo pode se ver claramente a gama de valores do menor CV aumentar gradativamente (vide Figura 7.10). Ambos resultados são

esperados, se os efeitos da remoção de pontos de dados são considerados. Como no caso do teste do coeficiente de variação, valores limites entre 0.25 e 0.30 são apropriados, mas o valor de 0.30 é a melhor escolha. Se a proporção de dados perdidos for muito alta, valores entre 0.25 e 0.35 poderiam ser considerados inconclusivos, e todos os valores de menor CV fora dessa faixa, ainda proveriam informações significantes.

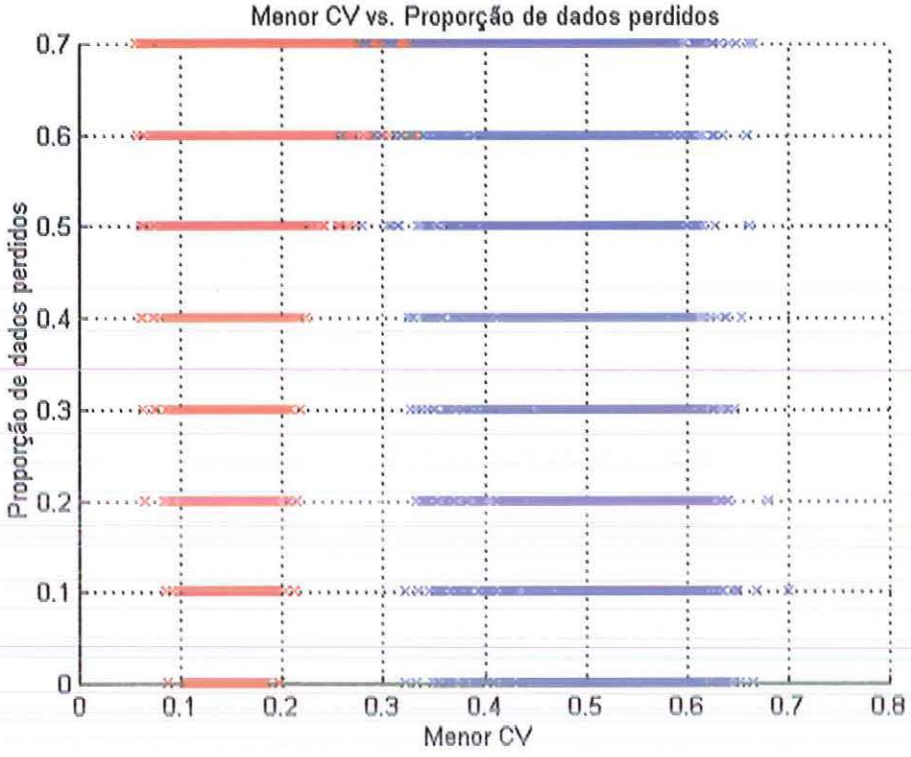

Figura 7.10 – Variação do menor *CV* versus proporção de dados perdidos. Trens não fundidos em vermelho, e resultados para trens fundidos em azul.

7.2.2.3 Teste do período de aquisição

Sob condições de teste normais, 10 – 30 segundos de dados são usualmente coletados. Sendo assim, é simples deduzir o número de pontos de dados (i.e. tempos de disparos) disponíveis no conjunto de dados;

$$N = \frac{período_aquisição}{IPI_médio} \tag{7.2}$$

É desejável que a métrica seja válida até mesmo sob pequenos períodos de aquisição, quer dizer, quando apenas uma quantidade limitada de dados está disponível. Por isso, períodos de aquisição entre 5 e 30 segundos foram simulados. As variações do menor CV com incrementos no período de aquisição são mostradas na Figura 7.11.

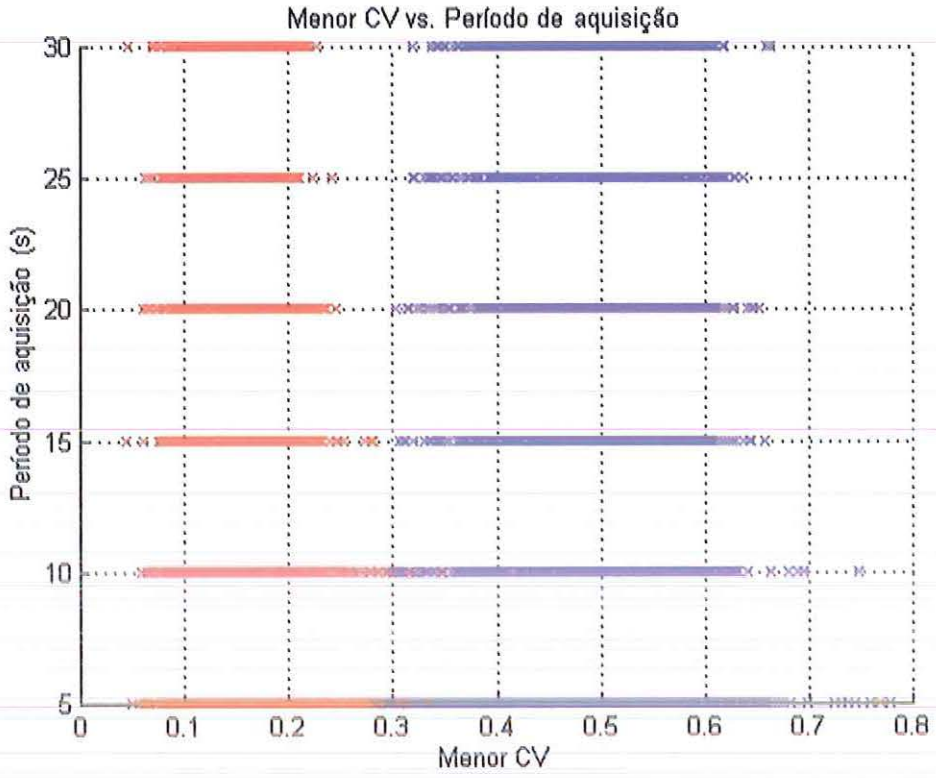

Figura 7.11 – Variações do menor *CV* versus período de aquisição.

Os dados mostram que, uma vez mais, o valor da métrica para trens fundidos relativamente não é afetado pelo decréscimo no período de aquisição. Para trens não fundidos, contudo, vemos a gama de valores do menor *CV* aumentar. Novamente, estes resultados são intuitivamente atraentes. Como no caso dos testes do coeficiente de variação e de dados perdidos, valores limites entre 0.25 e 0.30 são adequados para os períodos de amostragens típicos. Merece ser notado que a métrica não é de confiança para períodos de aquisição de 5 segundos ou menos. Observando um dos pontos de dados para trens não fundidos que caiu próximo de 0.76 para o menor *CV*, pode-se

concluir que tais períodos de aquisição curtos podem produzir saídas imprevisíveis (entretanto a probabilidade de erro ainda é muito pequena).

7.2.2.4 Teste da razão entre IPIs médios

Vários valores da razão entre IPIs médios de trens não fundidos foram testados, para descobrir algum possível comportamento estranho sob condições especiais. Razões entre 1 e 2.5 foram consideradas, isto cobre a gama completa de razões para valores IPIs médios típicos para trens não fundidos. A variação do menor *CV* para incrementos na relação entre os IPIs médios de dois trens não fundidos é mostrada na Figura 7.12.

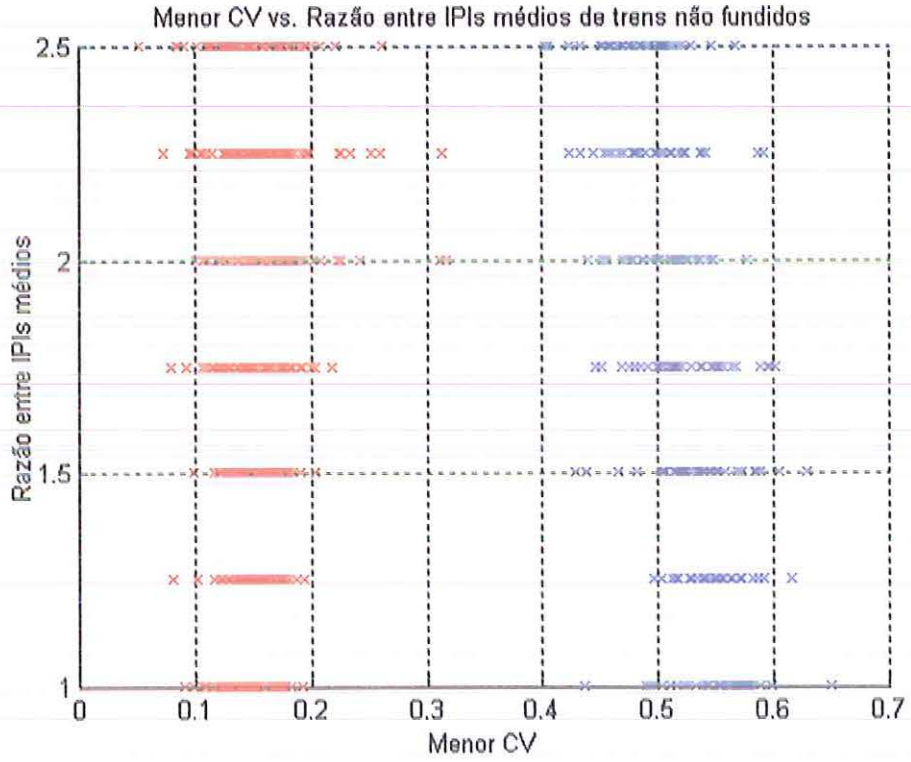

Figura 7.12 – Variação do menor *CV* versus razão entre IPIs médios de trens não fundidos

Pode ser visto do gráfico que a métrica não é afetada por esta relação, em ambos os casos. Nota-se que o resultado deste teste não teria afetado diretamente a escolha do valor limite para o menor *CV*, desde que as

relações eram desconhecidas na ocasião do teste. Apesar disso, o teste foi proveitoso uma vez que qualquer tendência sutil que porventura surgisse nos dados teria sido extraída.

7.2.3 Resultados da detecção de erros de classificação

Os menores *CVs* calculados para os quatros MUAPTs obtidos da decomposição, bem como o IPI médio e o desvio padrão, são listados abaixo:

MUAPT 1: $\mu = 62.8$ ms; $\sigma = 9.4$ ms; $CV = 0.15$

MUAPT 2: $\mu = 74.7$ ms; $\sigma = 14.3$ ms; $CV = 0.19$

MUAPT 3: $\mu = 99$ ms; $\sigma = 13$ ms; $CV = 0.13$

MUAPT 4: $\mu = 45$ ms; $\sigma = 12$ ms; $CV = 0.27$

Podemos notar de acordo com a métrica usada, que o menor CV em todos os casos ficou abaixo do limiar de 0.3 escolhido nos testes. Entretanto, não podemos deixar de notar que o valor encontrado para o MUAPT #4 ficou muito próximo do limiar, caindo dentro da faixa duvidosa e, portanto o teste não foi conclusivo para o MUAPT #4. No entanto, para os outros três MUAPTs o teste foi conclusivo, e podemos afirmar que não ocorreram erros de classificação.

7.3 Conclusões

Por hora o coeficiente de variação provê uma medida computacional razoável, com a qual se pode determinar se um trem de pulsos foi originado de um único neurônio ou não. O valor de 0.3 encontrado para o menor *CV* mostrou ser um valor adequado para detectar a presença de múltiplas fontes de neurônios em um trem de pulso.

Por não dispormos de um conjunto de dados "padrão de ouro", para testar o algoritmo usamos dados simulados. Entretanto, seria interessante que o algoritmo fosse testado extensivamente usando sinais mioelétricos reais, por exemplo, com mais de dois neurônios disparando dentro de um trem de pulso.

Recomenda-se também que outros métodos sejam examinados, como por exemplo, o método de autocovariância proposto por Gath, (1974), e possivelmente implementados como uma segunda peça de informação. Isto resultaria num classificador de dois parâmetros, levando a uma maior probabilidade de acerto na detecção de erros, obviamente a um custo computacional extra.

Podemos atribuir o sucesso da decomposição dos EMGs de superfície a dois fatores principais. O primeiro é uma seleção apropriada do pré-filtro; o pré-filtro é projetado para ter uma boa seletividade e uma forte redução da interferência de fundo, o que permite a detecção dos candidatos a MUAPs dominantes a partir de um sinal EMG altamente superposto e corrompido. O segundo fator é o uso da rede neural SOM como um classificador para identificar MUAPs individuais. Devido a alta variabilidade dos MUAPs, aliado ao fato de os MUAPs candidatos captados a partir de EMGs de superfície serem altamente corrompidos e ruidosos, os padrões de MUAPs são difíceis de classificar e reconhecer. Métodos tradicionais, como "*template matching*", falham na solução do problema por terem uma pobre redução de ruído. Redes neurais artificiais são capazes de encontrar características escondidas nos padrões e representa-las em um espaço multidimensional com limites de decisão não-lineares formado por aprendizagem. A implementação adicional do módulo de checagem do período refratário contribui para melhorar o algoritmo de decomposição.

Todas as simulações e testes realizados neste capítulo foram implementados em ambiente MATLAB versão 6.1.

CAPÍTULO 8

ESTUDO CLÍNICO A PARTIR DE CARACTERÍSTICAS MORFOLÓGICAS DOS MUAPS

8.1 Introdução

Nos primórdios da EMG, os neurologistas avaliavam as formas dos Potenciais de Ação das Unidades Motoras (MUAPs) observando-as no osciloscópio e escutando suas características de áudio. Com esses meios simples, era possível para um eletrofisiologista detectar anomalias com razoável precisão. Contudo, a avaliação dos MUAPs embora fosse satisfatória para a detecção de anomalias óbvias, não era adequada para desvios menos aparentes ou padrões de anormalidades misturados. Estes casos ambíguos exigiram a análise quantitativa do MUAP. Buchthal e colaboradores (1954a e 1954b), introduziram métodos manuais para análise quantitativa de MUAPs, onde os MUAPs eram registrados fotograficamente e então selecionados para análise. Medidas manuais dos parâmetros no domínio do tempo como duração, amplitude, e números de passagens pela linha de base foram realizados com esse método. Vinte potenciais foram coletados de cada músculo, e seus dados foram então comparados com valores obtidos de músculos de sujeitos normais de mesma idade. Apesar da importância que tiveram na ocasião, os métodos manuais consumiam tempo demais além de se sujeitarem a diversas fontes de erros devido a medidas subjetivas dos parâmetros dos MUAPs.

O advento da tecnologia computacional nos últimos anos permitiu aos cientistas renovarem seus esforços na análise de EMGs para aperfeiçoar a

avaliação de desordens neuromusculares. O processamento de EMGs auxiliado por computador reduz tempo, padroniza medidas e habilita a extração de características que não podiam ser calculadas manualmente. A análise de EMGs auxiliada por computador têm sido realizada nos domínios do tempo e da freqüência. Técnicas no domínio do tempo que dependem da extração de características para classificação diretamente da forma de onda do MUAP, tais como a duração, são algumas vezes difíceis de medir automaticamente, enquanto sua medida manual depende de um certo grau de intuição. Por outro lado, análise de sinais no domínio da freqüência revelam as características de freqüência dos sinais dos MUAPs. Contudo, esta análise baseada na estimativa do espectro de potência por transformada de Fourier (TF), padece dos efeitos de espalhamento espectral e da reduzida resolução espectral. As limitações inerentes aos métodos clássicos de estimação da densidade espectral de potência (DEP) podem ser superadas (ou melhoradas) pelas técnicas de modelagem paramétrica tais como a autoregressiva (AR), ou a média móvel autoregressiva (ARMA). Estas técnicas geram melhores estimadores, alta resolução espectral, e evitam os efeitos de espalhamento espectral, comparadas às técnicas não paramétricas ou de estimação espectral clássicas.

A análise AR de MUAPs em estudos clínicos foi sugerida como ferramenta de diagnóstico por Coatrieux (1983), além de outros pesquisadores, mas não foi investigada em detalhes. Além disso, a análise cepstral que vêm sendo aplicada no reconhecimento de voz já há algum tempo e mais recentemente em padrões de movimentos de EMG de superfície, Kang et al. (1997), não têm, contudo sido aplicada na análise de MUAPs.

Este capítulo tem como objetivo investigar a utilidade das características dos MUAPs extraídos pelo sistema de decomposição, no auxílio ao diagnóstico de desordens neuromusculares. Os MUAPs usados

neste estudo foram extraídos de sujeitos normais (**NOR**), de sujeitos sofrendo de doenças dos neurônios motores (**NMO**) e miopatias (**MIO**). Os seguintes conjuntos de características foram estudados:

(i) medidas no domínio do tempo;
(ii) medidas espectrais;
(iii) coeficientes AR e;
(iv) coeficientes cepstral.

Neste capítulo avaliamos o poder discriminativo de várias características selecionadas desses conjuntos através de análise estatística, bem como a performance de classificação dos quatro conjuntos de características para o diagnóstico de desordens neuromusculares, usando modelos de redes neurais artificiais (RNAs).

A organização deste capítulo foi feita como descrito a seguir. Seção 8.2 descreve o material. Seção 8.3 descreve o método de gravação dos EMGs, e a análise no domínio do tempo. Seção 8.4 descreve a modelagem AR e cepstral. Seção 8.5 descreve a classificação de patologias neuromusculares com redes neurais. Seção 8.6 mostra os resultados e discussões e a Seção 8.7 as observações e conclusões.

8.2 Material

Neste estudo, um total 480 MUAPs foram coletados do músculo bíceps braquial de 8 sujeitos **NOR**, 8 **NMO** e 8 **MIO**. Os critérios de diagnóstico foram baseados em opinião clínica, dados bioquímicos e biópsia. Somente sujeitos sem nenhuma história ou sinais de desordens neuromusculares foram incluídos no grupo normal. O músculo bíceps braquial foi examinado porque é um músculo proximal da cinta do ombro que é comumente afetada nos estágios iniciais nos dois grupos de patologias. Além

disso, o fato de ser facilmente acessível o torna atrativo para estudos, sendo também amplamente reportado na literatura.

8.3 Coleta de dados e análise no domínio do tempo

O sinal EMG foi adquirido do músculo bíceps braquial usando eletrodos de superfície diferenciais, conforme protocolo descrito no capítulo 5. Em seguida o sinal EMG foi filtrado em banda de 20 Hz à 2 kHz, e amostrado a 10 kHz por 10 s com 12 bits de resolução. Usamos o algoritmo de decomposição desenvolvido nesta tese para identificar os MUAPs gravados da mesma unidade motora. Os MUAPs do mesmo grupo foram alinhados pelo maior pico positivo. Este método produziu bons resultados, exceto no caso de MUAPs com alta variabilidade na forma, nesses casos desprezamos as amostras. O envelope médio do MUAP (*protótipo*) foi obtido pela média dos MUAPs do mesmo grupo, que será a partir daqui chamado de MUAP. Como desejamos analisar alterações morfológicas peculiares dos MUAPs, que são refletidas por desordens neuromusculares, precisamos além da duração do pico principal e da amplitude, detectar também inflexões e passagens pela linha de base, que ocorrem antes e depois do pico principal, por isto precisamos aumentar a duração da medida. A largura da janela de captura do MUAP foi aumentada de 12,8 ms para 25,6 ms. Portanto, a forma de onda do MUAP consistiu de 256 pontos (25,6 ms) ajustada para ter o maior pico na região de 100 pontos (10ms). Um algoritmo foi desenvolvido para medir automaticamente as seguintes características morfológicas do MUAP no domínio do tempo, conforme mostra a Figura 8.1:

1. Duração (***Dur***): identificada deslocando uma janela de medida c/ comprimento 3 ms e altura $\pm$ 25 μV;

2. Duração de pico (***Durpic***): medida do primeiro ao último pico positivo;

3. Amplitude (***Amp***): diferença entre o máximo pico positivo e o máximo pico negativo;

4. Área (***Área***): do MUAP retificado integrado sobre a duração da medida;

5. Área de pico (***Areapic***): do MUAP retificado integrado sobre a duração de pico;

6. Fases (***fas***): número de passagens pela linha de base que excederam 25 μV;

7. Inflexões (***inf***): número de picos negativos e positivos separados do anterior e do seguinte por menos de 25 μV.

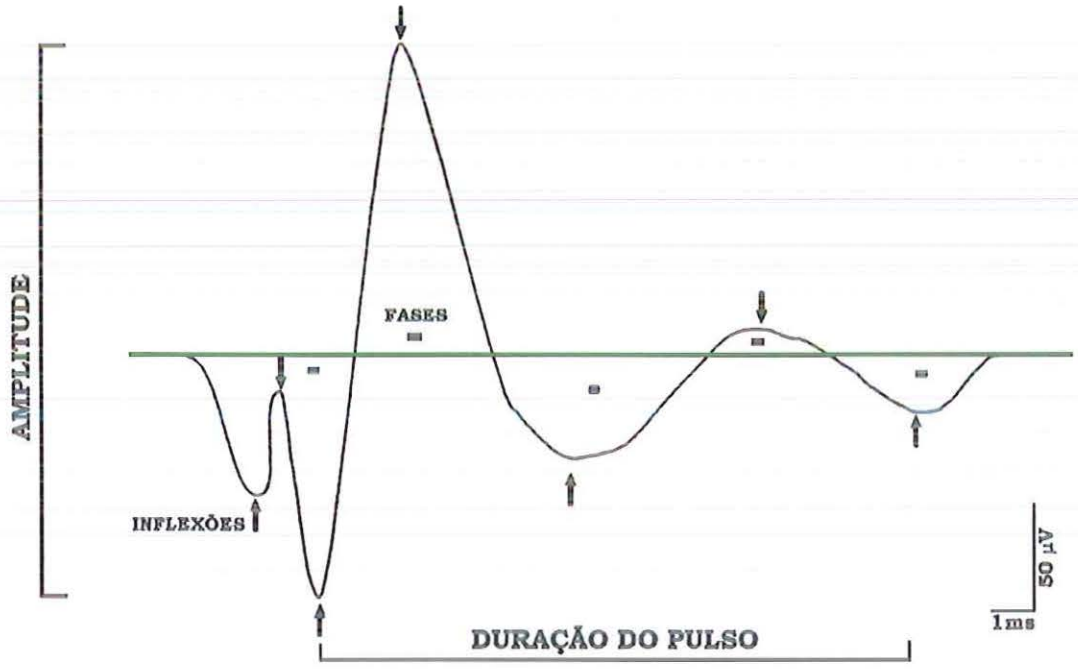

Figura 8.1 – Parâmetros morfológicos do MUAP no domínio do tempo.

Vinte MUAPs de cada UM foram gravados de cada sujeito. Assim cada sujeito foi representado com um vetor de tamanho 20 × 256 amostras. O

MUAP *protótipo* foi obtido pela média dos vinte MUAPs de cada UM gravados de cada sujeito, sendo portanto representativo da patologia associada ao paciente.

8.4 Modelagem autoregressiva e cepstral

8.4.1 Teste de estacionaridade

Modelos AR requerem que o sinal seja estacionário sobre o intervalo dado. Pode-se aplicar o modelo AR a um processo não-estacionário desde que o mesmo possa ser considerado como localmente estacionário. Resultados dos testes realizados por Bendatt & Piersol (1986), mostraram que para intervalos menores que 1s o critério de estacionaridade é aceito para o sinal EMG. Os sinais de MUAPs que usamos têm duração de 25,6 ms, estando portanto bem abaixo do limite de 1s encontrado nos testes.

8.4.2 Modelagem AR e seleção da ordem do modelo

O modelo AR de uma amostra corrente do sinal $x(n)$ é descrito como uma combinação linear de amostras prévias mais um termo de erro $e(n)$ que é independente de amostras passadas:

$$x(n) = -\sum_{k=1}^{p} a_k x(n-k) + e(n) \qquad n = 0,1,\ldots,N-1 \tag{8.1}$$

Onde $x(n)$ são amostras do sinal modelado, a_k são os coeficientes AR, p é a ordem do modelo, $e(n)$ é uma série temporal de valores residuais (erro de predição), e $N = 256$.

O modelo pode ser interpretado como um sistema linear c/ ***e(n)*** como entrada (ruído branco) e ***x(n)*** a saída (serie temporal de MUAPs). A função de transferência ***H(z)*** para o processo AR é:

$$H(z) = \frac{X(z)}{E(z)} = \frac{1}{1 + \sum_{k+1}^{p} \alpha_k z^{-k}} \tag{8.2}$$

O espectro do modelo pode ser estimado da Equação (8.2) como:

$$P_{AR}(w) = \frac{1}{\left| 1 + \sum_{k=1}^{p} \alpha_k e^{jwk} \right|^2} \tag{8.3}$$

Foi assumido que o espectro de $e(n)$ satisfaz $|E(w)|$, assim para o modelo apropriado de ordem p ele aproxima uma seqüência de ruído branco. Os coeficientes AR, α_k, foram calculados usando o algoritmo de covariância descrito por Marple (1987).

O valor ótimo para a ordem do modelo foi estimado pela minimização do critério dado pela função abaixo:

$$C(p) = N \cdot \ell n(\hat{\rho}_p) + 2p \tag{8.4}$$

Onde $\hat{\rho}_p$ é a variância estimada do erro de predição linear para o modelo de ordem p. Após ter sido selecionada a ordem do modelo, o ajuste do modelo foi verificado usando o periodograma de $e(n)$ resíduos, o periodograma normalizado de energia residual, e o periodograma normalizado cumulativo de resíduos.

8.4.3 Estimação espectral

O espectro de potência AR estimado de cada MUAP foi normalizado para o valor máximo de potência, e as seguintes medidas de freqüência e potência foram derivadas:

1. Largura de banda (***LB***): diferença entre as freqüências superior (F_2) e inferior (F_1), 3 dBs acima e abaixo respectivamente no espectro de potência, $LB = F2 - F1$;

2. Fator de qualidade (***Q***): Razão do pico de freqüência dominante (F_0) dividido por *LB*, $Q = F_0 / LB$;

3. Os momentos de ordem 0, 1 e 2, (valor médio, valor médio quadrático e variância respectivamente), foram computados como sugerido por Lindstrom & Petersen (1983), para $j = 0$, 1 e 2:

$$M_j = \frac{2}{(2\pi)^{j+1}} \sum_{n=0}^{N-1} x(n)^j P_{AR}(x(n)) \qquad (8.5)$$

4. Freqüência central ou freqüência de potência média (***FC***) definida como:

$$FC = \frac{\sum_{n=0}^{N-1} x(n) \cdot P_{AR}(x(n))}{\sum_{n=0}^{N-1} P_{AR}(x(n))} = \frac{M_1}{M_0} \qquad (8.6)$$

5. Freqüência mediana (***FMED***): Freqüência na qual o espectro de potencia é dividido em duas regiões c/ igual potência definida como:

$$\sum_{n=0}^{FMED-1} P_{AR}(x(n)) = \sum_{FMED}^{N-1} P_{AR}(x(n)) \qquad (8.7)$$

8.4.4 Análise cepstral

O cepstrum de um sinal é definido como a transformada de Fourier inversa do logaritmo do espectro de potência do sinal. Alternativamente, os coeficientes cepstrais podem ser derivados a partir dos coeficientes AR usando a fórmula abaixo:

$$\begin{aligned} c_1 &= -\alpha_1 \\ c_n &= -\alpha_n - \sum_{k=1}^{n-1}(1-k/n)\alpha_k c_{n-k} \text{ para } 1 < n \le p \\ c_n &= -\sum_{k=1}^{n-1}(1-k/n)\alpha_k c_{n-k} \text{ para } n > p \end{aligned} \tag{8.8}$$

Onde α_n e C_n denotam o enésimo coeficiente AR e cepstral respectivamente.

8.5 Classificação de patologias com redes neurais

Foram desenvolvidos três modelos de redes neurais artificiais (RNAs) para classificação das características dos MUAPs em três grupos: **NOR**, **NMO** e **MIO**. A motivação por trás do uso de RNAs repousa na capacidade delas não necessitarem de nenhuma suposição sobre as funções densidade de probabilidade subjacente dos dados de entrada, encontrar soluções próximas do ótimo para conjuntos de dados incompletos, e ao fato da aprendizagem ser realizada por treinamento. Para cada sujeito, foi computado o MUAP protótipo (vetor médio de 20 MUAPs), e o conjunto de características para este vetor médio extraído e usado como entrada para os classificadores. Quatro diferentes conjuntos de características foram extraídos das formas de onda dos MUAPs como descrito nas seções 8.3 e 8.4, sendo listados abaixo:

1. Parâmetros no domínio do tempo (n = 7): *Dur*, *Durpic*, *Amp*, *Área*, *Areapic*, *Fas*, *Inf*;
2. Parâmetros no domínio da freqüência (n = 7): M_0, M_1, M_2, *FMED*, *FC*, *LB*, *Q*;
3. Coeficientes autoregressivos (n = 12): α_1 até α_{12} ;
4. Coeficientes cepstral (n =12): c_1 até c_{12}.

Onde ***n*** é o número de características.

Três diferentes classificadores neurais foram investigados, o "*back-propagation*" (**BP**), a rede de função de base radial (**RBF**), e o mapa de características auto-organizáveis (**SOM**). Estes algoritmos foram implementados como sugerido na "*toolbox*" de rede neural para MATLAB, (Demuth & Beale, 1996).

8.6 Resultados e discussões

Um total de 480 MUAPs foram analisados, adquiridos de 8 sujeitos **NOR**, 8 **NMO** e 8 **MIO**, conforme procedimento descrito no capítulo 5. Os MUAPs foram extraídos e classificados em suas respectivas UMs via procedimento de decomposição desenvolvido nesta tese. Nesta seção são apresentados e discutidos os conjuntos de características extraídos dos MUAPs, através de análise estatística e verificação da performance das características para classificação de patologias por meio de RNAs.

8.6.1 Análise no domínio do tempo

Os parâmetros no domínio do tempo são os mais largamente usados em neurofisiologia clínica para interpretação dos achados eletromiográficos (Stalberg et al., 1986).

As seguintes características foram computadas das formas de onda dos MUAPs como apresentadas na Seção 8.3, e ilustradas na Figura 8.1: duração, duração do pico, amplitude, área, área do pico, número de fases e número de inflexões. As estatísticas para os grupos **NOR**, **NMO** e **MIO** foram tabuladas na Tabela 8.1.

Tabela 8.1 – Estatísticas dos parâmetros do MUAP no domínio do tempo para os grupos NOR, NMO, e MIO.

Classe	Duração (ms)		Duração do pico (ms)		Amplitude (μV)		Área (μV.ms)		Área do pico (μV.ms)		Fases	
	med	DP	Med	DP	med	DP	med	DP	med	DP	med	DP
NOR	9.60	2.75	5.40	2.46	376	306	370	198	232	118	2.6	0.8
NMO	13.42	3.86	6.86	4.09	614	426	832	590	520	369	4.0	1.8
MIO	7.15	2.34	4.21	1.83	314	250	234	193	163	132	2.7	1.0

Classe	Inflexões	
	med	DP
NOR	3.0	2.0
NMO	4.7	2.5
MIO	3.1	1.2

Para o grupo **NOR**, os valores da média (***med***) e do desvio padrão (***DP***) computados para duração, amplitude, e número de fases foram 9.60 $\pm$ 2.75 ms, 376 $\pm$ 306 μV e 2.6 $\pm$ 0.8 respectivamente. Já para o grupo **NMO**, estes valores foram 13.43 $\pm$ 3.86 ms, 614 $\pm$ 426 μV, e 4.0 $\pm$ 1.8, respectivamente. *Em pacientes sofrendo de doenças dos neurônios motores, tipicamente a duração média e a amplitude média dos MUAPs são maiores, e o número de fases é aumentado. Nestas patologias há um aumento no número ou densidade das fibras na unidade motora devido à desenervação das unidades motoras.* Há também um aumento na dispersão temporal da atividade captada pelo eletrodo. Este efeito é o resultado da redução da velocidade de condução ao longo das terminações das fibras nervosas individuais, e/ou um aumento em direção da zona de terminação da placa

motora. Para o grupo **MIO**, os valores da média e do desvio padrão computados para duração, amplitude, e número de fases foram 7.15 $\pm$ 2.34 ms, 314 $\pm$ 250 μV, e 2.7 $\pm$ 1.0, respectivamente. *MUAPs de curta duração e amplitude reduzida são encontrados tipicamente em pacientes sofrendo miopatias. Isto é atribuído a perda de fibras dentro da unidade motora, o grau de redução desses parâmetros reflete a quantidade de fibras perdidas.*

8.6.2 Análise autoregressiva

Os coeficientes AR e a ordem do modelo foram computados como descrito na Seção 4.2. O valor ótimo encontrado para a ordem do modelo ficou em torno de $p = 12$. Os valores da média (***med***) e o desvio padrão (***DP***) para os coeficientes α_1 até α_2 do modelo de ordem p são dados na Tabela 8.2.

Tabela 8.2 – Estatísticas do modelo de ordem p, e coeficientes AR α_1 até α_{12} para os grupos NOR, NMO, e MIO.

Classe	Ordem (p)		α_1		α_2		α_3		α_4	
	med	DP	med	DP	med	DP	med	DP	med	DP
NOR	6.08	3.01	-1.668010	0.420822	1.092608	0.691752	-0.417521	0.641230	0.210669	0.486064
NMO	7.67	4.19	-1.723160	0.439856	1.214877	0.718538	-0.635927	0.671467	0.339362	0.522950
MIO	5.98	3.28	-1.579977	0.415501	1.204518	0.589850	-0.631906	0.571509	0.330669	0.463620

Classe	α_5		α_6		α_7		α_8		α_9	
	med	DP	med	DP	med	DP	med	DP	med	DP
NOR	-0.130027	0.371162	0.113423	0.293977	-0.091136	0.234101	0.018550	0.192322	0.017705	0.182741
NMO	-0.165833	0.417175	0.114510	0.345164	-0.096369	0.296878	0.079257	0.261214	-0.045432	0.237154
MIO	-0.192223	0.365019	0.105285	0.271477	-0.060686	0.219653	0.046554	0.194694	-0.020974	0.158845

Classe	α_{10}		α_{11}		α_{12}	
	med	DP	med	DP	med	DP
NOR	-0.000872	0.136583	0.000612	0.093753	-0.002984	0.081842
NMO	-0.005655	0.220224	0.019720	0.188069	-0.000086	0.15883
MIO	0.013743	0.117944	-0.008572	0.105679	0.010371	0.097425

Para o grupo **NOR**, os valores da média e desvio padrão do modelo de ordem p foram 6.08 $\pm$ 3.01, para o grupo **NMO** foram 7.67 $\pm$ 4.19, e para o

grupo **MIO** foram 5.98 ± 3.28. Estes resultados mostram que modelos de ordem mais alta foram necessários para os sujeitos **NMO** comparados aos sujeitos **NOR**, devido a maior complexidade da forma nos sinais do grupo **NMO**. Por outro lado, modelos de ordem ligeiramente inferior foram obtidos para o grupo **MIO** comparados aos do grupo **NOR**, devido às formas de ondas mais simples do grupo **MIO**.

8.6.3 Estimativas espectrais

As seguintes medidas de freqüência e potência foram determinadas do espectro de potência para cada MUAP: *FC*, *FMED*, F_0, F_1, F_2, *LB*, *Q*, M_0, M_1, M_2. Os valores da média e desvio padrão para essas medidas são dados na Tabela 8.3.

Tabela 8.3 – Estatísticas das medidas espectrais AR para os grupos NOR, NMO, e MIO.

Classe	Freq. central [*FC*] (Hz)		Freq. mediana [*FMED*](Hz)		Freq. dominante [F_0] (Hz)		Freq. inferior [F_1] (Hz)		Freq. superior [F_2] (Hz)		Largura de banda [*LB*] (Hz)		Fator de qualidade [*Q*]		Momento M_0 (μV^2)	
	med	DP	med	DP	med	DP	med	DP	med	DP	med	DP	med	DP	med	DP
NOR	261	161	206	142	108	139	30	98	280	214	250	204	0.47	0.57	20.71	15.02
NMO	223	141	169	120	106	120	56	118	221	180	165	154	0.71	0.98	15.30	11.80
MIO	377	177	314	166	205	194	96	194	435	274	339	225	0.63	0.78	29.70	16.88

Classe	Momento M_1 ($\mu V^2/s10^3$)		Momento M_2 ($\mu V^2/s^2 10^6$)	
	med	DP	med	DP
NOR	15.34	23.06	24.52	51.95
NMO	9.54	17.59	14.12	39.70
MIO	27.68	27.18	45.41	64.95

Os valores da média e desvio padrão de *FC* para os grupos **NOR**, **NMO**, e **MIO** foram: 261 ± 161, 223 ± 141, 377 ± 177 Hz respectivamente. Similarmente, *FMED* para os grupos **NOR**, **NMO**, e **MIO** foram respectivamente: 206 ± 142, 169 ± 120, e 314 ± 166 Hz. Pode-se ver

claramente que no caso do grupo **MIO**, *FC* e *FMED* foram maiores comparadas ao grupo **NOR**, isso mostra que o espectro de potência no caso de miopatias foi deslocado em direção das altas freqüências. Esta observação foi reportada por Lindstrom & Petersen (1983), e em vários outros estudos. Por outro lado, no caso do grupo **NMO**, *FC* e *FMED* foram menores comparadas ao grupo **NOR**, mostrando que o espectro de potências foi deslocado em direção das baixas freqüências. Isto também foi reportado em Lindstrom & Petersen (1983). Além disso, a *LB* no grupo **MIO** foi maior do que no grupo NOR, com o reverso sendo válido para o grupo **NMO**.

Os momentos espectrais de ordem 0, 1, e 2 são também tabulados na Tabela 8.3. O momento espectral M_0 é na verdade a potência média do espectro. O momento M_0 foi maior para o grupo **MIO** comparado ao grupo **NOR**. Reciprocamente, M_0 foi menor para o grupo **NMO** comparado ao grupo **NOR**. Todos os parâmetros de freqüência encontrados para o grupo **MIO** foram maiores do que os dos grupos **NOR** e **NMO**. E reciprocamente, todos os parâmetros de freqüência encontrados para o grupo **NMO** foram inferiores aos dos grupos **NOR** e **MIO**.

8.6.4 Análise cepstral

Doze coeficientes cepstral, c_1 à c_{12} foram determinados diretamente dos coeficientes AR estimados, α_1 à α_{12}. As estatísticas para os grupos **NOR**, **NMO**, e **MIO** são apresentadas na Tabela 8.4. A motivação para o uso de coeficientes cepstral como características para o diagnóstico neste estudo se deve ao seu uso bem sucedido no reconhecimento de voz, além de inúmeras publicações de vários pesquisadores atestando sua alta precisão no reconhecimento de voz comparado aos coeficientes AR. Além disso, em um estudo realizado por Kang e colaboradores (1997), verificou-se a capacidade dos coeficientes cepstral para classificação de padrões de movimento através

de sinais EMG de superfície, e foi reportado que os coeficientes cepstral mostraram uma separabilidade significativamente melhor comparada aos coeficientes AR.

Tabela 8.4 – Estatísticas dos coeficientes cepstral c_1 à c_{12} para os grupos NOR, NMO, e MIO.

Classe	c_1		c_2		c_3		c_4		c_5	
	med	DP	med	DP	med	DP	med	DP	med	DP
NOR	1.668010	0.420822	0.386697	0.431402	0.200811	0.215739	0.123910	0.151817	0.101349	0.118718
NMO	1.723160	0.439856	0.366177	0.421948	0.30473	0.243998	0.89913	0.180572	0.131919	0.151253
MIO	1.579977	0.415501	0.129635	0.384323	0.080628	0.180367	0.014515	0.128453	0.021473	0.132818

Classe	c_6		c_7		c_8		c_9		c_{10}	
	med	DP	med	DP	med	DP	med	DP	med	DP
NOR	0.049142	0.116364	0.040310	0.137804	0.037209	0.144269	0.020981	0.179839	0.023168	0.212216
NMO	0.027882	0.146572	0.057157	0.177345	0.022531	0.199724	0.007635	0.225184	0.025021	0.261658
MIO	0.006215	0.124227	-0.003685	0.119866	-0.012868	0.109165	-0.005609	0.109275	0.005091	0.134606

Classe	c_{11}		c_{12}	
	med	DP	med	DP
NOR	0.024834	0.291446	0.040019	0.366013
NMO	0.017820	0.308422	0.027882	0.386145
MIO	0.017915	0.138857	0.019449	0.131812

8.6.5 Classificação de patologias com redes neurais

Os 480 MUAPs obtidos dos 24 sujeitos avaliados foram divididos em dois grupos. Para treinamento dos classificadores RNAs, foram usados um total de 240 MUAPs obtidos de 12 sujeitos, 4 NOR, 4 NMO, e 4 MIO. Enquanto para avaliação foram usados também um total de 240 MUAPs obtidos de outros 12 sujeitos, 4 NOR, 4 NMO, e 4 MIO. O sistema foi treinado e avaliado usando os quatro conjuntos de características diferentes. Para o treinamento, em cada conjunto as características dos 12 sujeitos diferentes foram selecionadas de forma randômica, e para avaliação da forma descrita acima. Para cada sujeito, o vetor médio de 20 MUAPs por sujeito (*protótipo*) foi usado para computar cada conjunto de características, que em

seguida foi usado como entrada para os classificadores. A Tabela 8.5 mostra a média e o desvio padrão da porcentagem de classificações corretas de cada modelo de RNA para cada conjunto de características, mostrando ainda o percentual médio do diagnóstico produzido para cada conjunto de características.

Como podemos observar na coluna *Diagnóstico Médio* da Tabela 8.5, o melhor diagnóstico foi obtido para os parâmetros no domínio do tempo 78.3%, seguido pelos coeficientes cepstral 63.7%, parâmetros no domínio da freqüência 62.5%, e por último os coeficientes auto-regressivos com 51,2%.

É importante notar que os parâmetros no domínio do tempo são os únicos parâmetros que são extensivamente usados em neurofisiologia clínica para avaliação de desordens neuromusculares, e em nossos ensaios foram os que produziram os melhores diagnósticos. Além disso, a melhor performance dos coeficientes cepstral sobre os coeficientes auto-regressivos para EMGs de superfície também foi reportada por Kang e colaboradores, (1997).

Tabela 8.5 – Média e desvio padrão do diagnóstico produzido por cada modelo de classificador para cada conjunto de características.

Conjunto de características	n*	Back-propagation BP (Diag%)	Rede de função de base radial RBF (Diag%)	Mapas de características auto-organizáveis SOM (Diag%)	Diagnóstico médio (Diag%)
(i) Domínio do tempo: (duração, duração do pico, área, área do pico, fases, e inflexões)	7	81.2±11.8	72.5±8.5	81.2±5.5	78.3±8.6
(ii) Domínio da freqüência: (momentos M_0, M_1, e M_2, freqüência mediana, largura de banda, e fator de qualidade)	7	63.7±2.5	60.0±6.3	63.7±10.1	62.5±6.3
(iii) Auto-regressiva (α_1 a α_{12})	12	56.2±7.9	50.0±6.8	47.5±10.1	51.2±8.3
(iv) Cepstral (c_1 a c_{12})	12	62.5±15.8	60.0±5.0	68.7±3.9	63.7±8.2

*n é o número de características em cada conjunto.

8.7 Observações e conclusões

Neste capítulo investigamos as alterações morfológicas dos MUAPs extraídos via decomposição para produção de diagnósticos, bem como sua correlação com as mudanças fisiológicas típicas que ocorrem nas desordens neuromusculares estudadas. Deve-se enfatizar que se o processo patológico está num grau avançado e as anormalidades eletrofisiológicas são muitas e óbvias, apesar da análise automática de EMGs ser de menor importância para o diagnóstico, ela pode ser útil para detectar e caracterizar mudanças em uma série de exames. Por outro lado, a aplicação da análise de EMGs auxiliada por computador é muito importante na detecção precoce de patologias e em casos brandos, onde as anormalidades eletrofisiológicas são relativamente insignificantes e podem escapar a um diagnóstico apurado.

Os resultados mostraram que os coeficientes cepstral produziram melhores resultados do que as medidas espectrais e os coeficientes AR. Apesar disso, os diagnósticos produzidos obtidos com os parâmetros no domínio do tempo foram melhores do que com os coeficientes cepstral. A combinação dos resultados de diferentes características e diferentes classificadores aumenta a probabilidade de que erros de características individuais ou classificadores possam ser compensados pelos resultados restantes.

Trabalhos futuros poderiam investigar a interpretação dos coeficientes AR e cepstral em relação às mudanças fisiopatológicas musculares como: velocidade de propagação do MUAP, velocidade de dispersão, tamanho da zona de inervação, localização do eletrodo, número de fibras na unidade motora, etc. A análise wavelet motiva por suas características especiais a aplicação na análise de MUAPs, e poderia ser investigada também quanto a produção de diagnósticos .

Os padrões de disparos caracterizados pelos histogramas de IPI também refletem mudanças patológicas nas UMs, e deveriam ser investigados quanto à produção de diagnósticos e avaliação de mudanças fisiopatológicas neuromusculares, servindo como um recurso complementar no processo de tomada de decisão pelo clínico.

CAPÍTULO 9

CONSIDERAÇÕES FINAIS

A extração de MUAPs individuais a partir de EMGs de superfície é uma tarefa desafiadora, porém essencial em estudos clínicos e investigações neurofisiológicas. Neste trabalho, apresentou-se uma abordagem efetiva para a decomposição de EMGs de superfície baseada no uso do Mapa de Kohonen como classificador. Os resultados experimentais preliminares indicaram que nossa abordagem pode alcançar uma boa performance na decomposição de EMGs de superfície.

Podemos atribuir o sucesso da decomposição dos EMGs de superfície a dois fatores principais. O primeiro é uma seleção apropriada do pré-filtro; o pré-filtro é projetado para ter uma boa seletividade e uma forte redução da interferência de fundo, o que permite a detecção dos candidatos a MUAPs dominantes a partir de um sinal EMG altamente superposto e corrompido. O segundo fator é o uso da rede neural SOM como um classificador para identificar MUAPs individuais. Devido a alta variabilidade dos MUAPs, aliado ao fato de os MUAPs candidatos captados a partir de EMGs de superfície serem altamente corrompidos e ruidosos, os padrões de MUAPs são difíceis de classificar e reconhecer. Os métodos tradicionalmente usados na eletromiografia invasiva, como "*template matching*", falham na solução do problema por terem uma pobre redução de ruído. Redes neurais artificiais são capazes de encontrar características escondidas nos padrões e representa-las em um espaço multidimensional com limites de decisão não-

lineares formado por aprendizagem. A implementação adicional do módulo de checagem do período refratário contribui para melhorar o algoritmo de decomposição.

No entanto devemos salientar que algumas etapas do processo de decomposição ainda requerem a intervenção do operador, seja para fixar algum parâmetro de limiar, seja para descartar possíveis erros de classificações. Durante os testes dessa pesquisa, alguns parâmetros foram definidos experimentalmente e outros foram definidos de forma automatizada, através de procedimentos desenvolvidos para esse fim. Uma proposta futura seria o desenvolvimento de novos procedimentos que, através da análise do sinal EMG, pudesse sugerir valores para os parâmetros utilizados no processamento. Isto seria importante para sua efetiva aceitação em um ambiente clínico.

Ressaltamos que o número de MUAPTs reconhecidos ainda é relativamente baixo quando comparado com métodos invasivos. Isto se deve a necessidade de um baixo nível de contração muscular (5 – 10% da CVM) durante as aquisições, de forma a limitar o número de UMs ativas, e conseqüentemente reduzir o grau de superposição no sinal. Esta limitação foi imposta pelo tipo de eletrodo usado nas aquisições do sinal EMGS. Devemos ponderar que o eletrodo de superfície ativo diferencial usado para as aquisições, tem um efeito de filtragem espacial reduzido (comentado na seção 3.2). Assim sendo, podemos esperar obter resultados superiores, com o uso de eletrodos com melhores características em termos de seletividade espacial, como o eletrodo NDD (citado na seção 3.2), que melhora a seletividade espacial em todas as direções, permitindo assim a separação não invasiva das atividades individuais das UMs mesmo sob altos níveis de contração.

O estudo clínico vem comprovar a utilidade do sistema de decomposição para avaliação de desordens neuromusculares, evidenciando a

eficiência dos parâmetros morfológicos no domínio do tempo na produção de diagnósticos. Ratificando seu uso já amplamente difundido em neurofisiologia clínica para interpretação dos resultados eletromiográficos. Contudo a combinação dos resultados de diferentes características e diferentes classificadores aumenta a probabilidade de que erros de características individuais ou classificadores possam ser compensados pelos resultados restantes.

CAPÍTULO 10

REFERÊNCIAS BIBLIOGRÁFICAS

ANDREASEN, S.; ROSENFALCK, A. **Recording from a single motor unit during strong efforts**. *IEEE Trans Biomed Eng* 25: 01-508, 1978.

BARKHAUS, P.; NANDEDKAR, S; SANDERS, D.B. **Quantitative EMG in inflammatory miopathy.** *Muscle & Nerve* 13: 247-253, 1990.

BASMAJIAN, J.; DE LUCA, C.J. **Muscle Alive: Their Functions Revealead by Electromyography.** Fifth ed. Baltimore, MD: Willians and Wilkins, 1985.

BENDAT, J.S.; PIERSOL, A.G. **Random data: analysis and measurement procedures.** *New York: Wiley Interscience, 1986.*

BISCHOFF, C.; STALBERG, E.V.; FALK, B.; EEG-OLOFSSON, K.E. **Reference values of motor unit action potentials obtained with multi-MUAP analysis.** *Muscle Nerve* 17: 842-851, 1994.

BROMAN, H. **Knowledge-based signal processing in decomposition of myoeletric signals**. *IEEE Eng Med Biol Mag* 7: 24-28, 1988.

BROMAN, H.; BILOTTO, G.; DE LUCA, C. **A note on noninvasive estimation of muscle fibre conduction velocity.** *IEEE Trans Biomed Eng, 32:311-319, 1985.*

BUCHTHAL, F.; ROSENFALK, P. **On the structure of motor units.** In: *New Developments in Electromyography and Clinical Neurophysiology*, Vol. ed. by Desmedt JE, Karger, Basel, 83-104, 1973.

BUCHTHAL, F.; PINELLI, P.; ROSENFALCK P. **Action potential parameters in normal human muscle and their physiological determinations**. *Acta Physiology Scandinavian* 32:219-229; 1954a.

BUCHTHAL, F.; PINELLI, P.; ROSENFALCK P. **Action potential parameters in normal human muscle and their dependence on physical variables**. *Acta Physiology Scandinavian* 32:200-215; 1954b.

CARPENTER, G. & GROSSBERG, S. **A massively parallel architecture for a self-organizing neural pattern recognition machine.** *Comp. Vision, Graphics and Image Proc.*, vol. 37, pp. 54-115, 1987.

CHRISTODOULOU, I.C.; PATTICHIS C.S. **Unsupervised pattern recognition for the classification of EMG signals.** *IEEE Trans. Biomed. Eng., 46:169-178, 1999.*

COATRIEUX, J.L. **Interference electromyogram processing – Part II: experimental and simulated EMG AR modeling.** *Electromyography Clinical Neurophysiology* 23:481-490; 1983.

CONWIT, R.; TRACY, B.; JAMISON, C.; MCHUGH, M.; STASHUK, D.; BROWN, W.B. **Firing rate analysis using decomposition enhanced spike-triggered averaging in the quadriceps femoris.** *Muscle & Nerve* 21: 1338-1340, 1998.

DE FIGUEIREDO, R.J.P.; GERBER, A. **Separation of superimposed signals by a cross-correlation method.** *IEEE Trans. Acoustics Speech Signal Processing* 31: 1084-1089, 1983.

DE LUCA, C.J. **The Use of Electromyography in Biomechanics.** *The International Society for Biomechanics,* 5 de July 1993a.

DE LUCA, C.J. **Precision decomposition of EMG signals.** *Meth Clin Neurophysiol*, 4:1-28, 1993b.

DE LUCA, C.J.; FOLEY, P.J.; ERIM, Z. **Motor unit control properties in constant-force isometric contraction.** *Journal of Neurophysiology* 4:1-28, 1996.

DE LUCA, C.J.; LEFEVER, R.S.; MCCUE, M.P.; XENAKIS, A.P. **Behaviour of human motor units in different muscle during linear-varying contractions.** *J. Physiol (London)*, 329: 113-128, 1982.

DEMUTH, H.; BEALE, M. **Neural network toolbox user guide.** *Natick, M.A.: The Maths Work Inc.,* 1996.

DISSLHORST-KLUG, C.; BAHM, J.; RAMAEKERS, V.; TRACHTERNA, A.; RAU, G. **Non-invasive approach of motor unit recording during muscle contractions in humans.** *European Journal of Applied Physiology* 83: 144-150, 2000.

DISSLHORST-KLUG, C.; SILNY, J.; RAU, G. **Estimation of the relationship between the noninvasively detected activity of single motor units and their characteristic pathological changes by modelling.** *Journal of Electromyography and Kinesiology* 8: 323-335, 1998.

DORFMAN, L.J.; HOWARD, J.E.; MCGILL, K.C. **Motor unit firing rates and firing rate variability in the detection of neuromuscular disorders.** *Electroencephalography Clinical Neurophysiology* 73:215-224, 1989.

ERIM, Z; BEG, F,; BURKE, D.T.; DE LUCA, C.J. **Effects of aging on motor-unit control properties.** *Journal of Neurophysiology* 82: 2081-2091, 1999.

FANG, J.; AGARWAL, G.C.; SHAHANI, B.T. **Decomposition of EMG signal by wavelet spectrum matching.** *Dept. of Rehab. Med. & Restor. Med. Sci.(MC-888), Univ. of Illinois at Chicago, Chicago, IL 60612, 1999a.*

FANG, J.; AGARWAL, G.C.; SHAHANI, B.T. **Decomposition of multiunit electromyographic signals.** *IEEE Trans. Biomed. Eng., 46:685-697, 1999b.*

FANG, J.; SHAHANI, B.T.; BRUYNINCKX, F.L. **Study of single motor unit discharge patterns using 1/F process model.** *Muscle & Nerve* 20: 293-298, 1997.

FARINA, D.; CESCON, C.; MERLETTI, R. **Influence the anatomical, physical, and detection-system parameters on surface EMG.** *Biological Cybernetics* 86: 445-456, 2002.

FARINA, D.; COLOMBO, R.; MERLETTI, R.; BAARE OLSEN, H. **Evaluation of intra-muscular EMG signal decomposition algorithms.** *Journal of Electromyography and Kinesiology* 11: 175-187, 2001.

FARINA, D.; RAINOLDI, A. **Compensation of the effect of subcutaneous tissue layers on surface EMG: a simulation study.** *Med Eng Phys* 21: 487–496, 1999.

FILLIGOI, G.C.; FELICI, F. **Detection of hidden rhythms in surface EMG signals with a nonlinear time-series tool.** *Medical Engineering & Physics* 21:(6-7) 439-448, 1999.

FUGLEVAND, A.J.; INTER, D.A.; PARLA, A.E.; STASHUK, D. **Detection of motor unit action potentials with surface electrodes: influence of electrode size and space.** *Biological Cybernetics* 67: 143-153, 1992.

GATH, I.; STALBERG, E. **Techniques for improving the selectivity of electromyographic recordings.** *IEEE Trans Biomed Eng* 26: 476-472, 1978.

GATH, I. **Analysis of point process signals applied to motor unit firings patterns.** *Mathematical Biosciences,* vol 22: 211-236, 1974.

GEMPERLINE, J.J.; ALLEN, S.;WALK, D.; RYMER, W.Z. **Characteristics of motor unit discharge in subjects with hemiparesis.** *Muscle & Nerve* 18: 1101-1114, 1995.

GERBER, A.; STUDER, R.M.; FIGUEIREDO, R.J.P.; MOSCHYTZ, G.S. **A new framework and computer program for quantitative EMG signal analysis.** *IEEE Trans Biomed Eng* 31: 857-863, 1984.

GONZALES, R. C. & WOODS, R. E. *Digital Image Processing*. Reading, MA: Addison-Wesley, 1992.

GRIEP, P.; GIELEN, F.; BOOM, H.; BOON, K.L.; HOOGSTRATEN, L.; POOL, C.; WALINGA-DE-JONGE W. **Calculation and registration of the same motor unit action potential.** *Electroencephalogr Clin Neurophysiol* 53: 3888-404, 1982.

GUIHENEUC, P.; CALAMEL, J.; DONCARLI, C.; GITTON, S.; MICHEL, C. **Automatic detection and pattern recognition of single motor unit potentials in needle EMG.** *Prog Clin Neurophysiol Karger, Basal* 10: 73-127, 1983.

GUT, R.; MOSCHYTZ, G.S. **High-precision EMG signal decomposition using communication techniques.** *IEEE Trans Signal Processing* 48: 2487-2494, 2000.

HASSOUN, M.H.; WANG, C.; SPITZER, A.R. **NNERVE: neural network extraction of repetitive vectors for electromyography – Part I: algorithm.** *IEEE Trans Biomed Eng* 41: 1039-1052, 1994.

HASSOUN, M.H.; WANG, C.; SPITZER, A.R. **NNERVE: neural network extraction of repetitive vectors for electromyography – Part II: Performance analysis.** *IEEE Trans Biomed Eng* 41: 1053-1062, 1994.

HEFFNER, G.; ZUCCHINI, W.; JAROS, G.G. **The electromyogram (EMG) as a control signal for functional neuromuscular stimulation – Part I: autoregressive modeling as a means of EMG signature discrimination.** *IEEE Transaction Biomedical Engineering* 35:597-604; 1988.

HERMENS, H.J.; FRERIKS, B. **Future Applications of Surface Electromyography.** *Proceedings of the fourth general SENIAM workshop's Hertogenbosch, the Netherlands,* September 1999.

HOWARD, J.E.; MCGILL, K.C.; DORFMAN, L.J. **Properties of motor unit action potentials whith concentric and monopolar needle electrodes: ADEMG analysis.** *Muscle & Nerve* 11: 1051-1055, 1988.

JAIN, A.K. **Algorithms for Clustering Data.** *Englewood Cliffs, NJ: Prentice Hall,* 1988.

JONSSON B.; BRAGGE UE. **Displacement, deformation and fracture of wire electrodes for electromyography.** *Electromyography* 8: 328-347, 1968.

KADEFORS, R.; FORSMAN, M.; ZOEGA, B.; HERBERTS, P. **Recruitment of low treshold motor-units in the trapezius muscle during different static arm positions.** Ergonomics 42: 359-375, 1999.

KANG, W; SHIU, J.R.; CHEN, C.K.; LAI, J.S.; TSAO, H.W.; KUO, T.S. **The application of cepstral coefficients and maximum likelihood method in EMG pattern recognition.** *IEEE Transactions Biomedical Engineering* 42(8):777-785; 1997.

KOHONEN, T. **Self-organizing formation of topologically correct feature maps.** *Biological Cybernetics*, 43(1): 59-69, 1982a.

KOHONEN, T. **Analysis of a simple self-organizing process.** *Biological Cybernetics*, 44(2):135-140, 1982b.

KOHONEN, T. **Self-Organizing Maps, 2nd Ed.**, *Springer-Verlag*: Berlin, 1997.

KOHONEN, T.; HYNNINEN, J.; KANGAS, J. & LAAKSONEN, J. *SOM_PAK: The Self-Organizing Map program package*. Report A31, Helsinki University of Technology, Laboratory of Computer and Information Science, January, 1996.

LEFEVER, R.S.; DE LUCA, C.J. **A procedure for decomposing the myoeletric signal into its constituent action potentials.** *IEEE Trans Biomed Eng* 29: 149-157, 1982.

LINDSTROM, L; PETERSEN, I. **Power spectrum analysis of EMG signals and its applications.** *In: Desmedt JE, editor. Computer-Aided Electromyography Prog Clin Neurophysiol*, vol. 10. Basel: Karger, 1983:1-51.

LOUDON, G.H.; JONES N.B.; SEHMI A.S. **New signal processing techniques for the decomposition of EMG signals.** Med. Biol Eng Comput 30: 591-599, 1992.

LYNN, P.A., BETTKES, N.D., HUGH, A.D., JOHNSON, S.W. **Influence of electrode geometry on bipolar recording of the surface electromiogram.** *Med Biol Eng Comput* 16: 651-660, 1978.

MARPLE, S.L. Jr. **Digital spectral analysis with applications.** *Englewood Cliffs: Prentice Hall, 1987.*

MASUDA, T.; MIYANO, H.; SADOYAMA, T. **A surface electrode array for detecting action potential trains of single motor units.** *Electroencephalogr Clin Neurophysiol* 60: 435-443, 1987.

MASUDA, T.; MIYANO, H.; SADOYAMA, T. **The Propagation of single motor unit action potentials detected by a suface electrode array.** *Electroencephalogr Clin Neurophysiol* 53: 590-598, 1986.

MASUDA, T.; SADOYAMA, T. **The Propagation of motor unit action potentials and the location of the neuromuscular junktion investigated by suface electrodes arrays.** *Electroencephalogr Clin Neurophysiol* 55: 594-600, 1986.

MCGILL, K.C.; CUMMINS, K.L.; DORFMAN, L.J. **Automatic decomposition of clinical electromyogram.** *IEEE Trans Biomed Eng* 32: 470-477, 1985a.

MCGILL, K.C.; DORFMAN, L.J. **Automatic decomposition electromyography (ADEMG): validation normative data in brachial biceps.** *Electroencephalogr Clin Neurophysiol* 61: 453-461, 1985b.

MCGILL, K.C.; DORFMAN, L.J. **Automatic decomposition electromyography (ADEMG): methodological and technical considerations.** In: Dessmedt, J.E. (eds.), *Computer-Aided Electromyography and Expert Systems* 91-101, 1989.

MCGILL, K.C.; HUYNH, A.; DORFMAN, L.J. **Automatic decomposition electromyography (ADEMG) performance evaluation using computer simulation.** Proceedings of the 9th annual International Conference of the IEEE Engineering in Medicine and Biology Society 350-352, 1997.

MEINECKE, L.; DISSELHORST-KLUG, C.; BAHM, J.; RAU, G. **Synchronous muscular co-ordination and 3-dimensional motion analysis in treatment of patients with obstetric plexus-lesion.** *Helmholtz-Institute for Biomedical Engineering, RWTH Aachen, Aachen/Germany-St. Franziskus Hospital, Aachen/Germany*

MERLETTI, R.; DE LUCA, C.J. **New techniques in surface electromyography**. In: Desmedt JE (ed) *Computer-aided electromyography and expert systems.* Elsevier, Amsterdam, pp 115-124, 1989.

MEYER, F.; BEUCHER, S. (1990). **Morphological Segmentation**, *Journal of Visual Comm. & Image Representation*, vol. 1, pp. 21-46, 1990.

NANDEDKAR, S.D.; BARKHAUS, P.E.; CHARLES, A. **Multi-motor unit action potential analysis (MMA).** *Muscle & Nerve 18: 1155-1166, 1995.*

NIKOLIC, M.; SORENSEN, J.A.; DAHL, K.; KRARUP, C. **Detailed analysis of motor unit activity.** *In: Proccedings of 19th annual International Conference of the IEEE Enginnering in Medicine and Biology Society Chicago* 1257-1260, 1997.

PAISS, O.; INBAR, G.F. **Autoregressive modeling of surface EMG and its spectrum with applications to fadigue.** *IEEE Transactions Biomedical Engineering* 34:761-770; 1987.

PATTIICHIS, S.C.; ELIA, G.A. **Autoregressive and cepstral analyses of motor unit action potentials**. *Medical Engineering Physics*, 21: 405-419, 1999.

PATTIICHIS, S.C.; SCHIZAS C.N.; MIDDLETON L.T. **Neural network models in EMG diagnosis.** *IEEE Trans Biomed Eng* 42: 486-496, 1995.

PARKER, J.R. *Algorithms for image processing and computer vision.* Wiley: New York, 1997.

PERKEL, D.; GERSTEIN, G. **Neural spike trains and stochastic point processes** *Biophys J.* 7: 391-418, 1967.

PFFEIFER, G.; KUNZE, K. **Frequency analysis and duration of motor unit potentials: Reability and diagnostic usefulness.** *Electroencephalography Clinical Neurophisiological* 89:365-374; 1993.

PFFEIFER, G.; KUNZE, K. **Discriminat classification of motor unit potentials (MUPs) successfully separates neurogenic and myopathic condition. A comparison of multi-and univarite dignostic algorithms for MUP anlysis.** *Electroencephalogr Clin Neurophysiol* 97: 191-207, 1995.

PHONSEY, R. **Quantitative formulations of electrophysical sources of potential fields in volume conductors.** *IEEE Trans Biomed Eng* 31: 868-872, 1984.

RAU, G.; DISSLHORST-KLUG, C. **Principles of high-spatial-resolution surface EMG (HSR_EMG): Single motor unit detection and Application in the diagnosis of neuromuscular disorders.** *Journal Of Electromyography And Kinesiology,* 7(4): 233-239, 1997.

REUCHER, H., RAU, G., SILNY, J. **Spatial filtering of non invasive multielectrode EMG: Part I – introduction to measuring technique and aplications.** *IEEE Trans Bio-Med Eng*, BME 34(2): 98-105, 1987.

ROSENFALCK P. **Intra and extracelular potential fields of active nerve and muscle fibers.** *Acta Physiology Scandinavian*, 61 (supp. 226): 1-96, 1964.

SCHNEIDER, J., RAU, G., SILNY, J. **A non invasive EMG technique for investigating the excitation propagation in single motor units.** *Electromyogr Clin Neurophysiol, 29: 273-280, 1989.*

SONOO, M.; STALBERG, E. **The ability of MUP parameters to discriminate between normal and neurogenic MUPs in concentric needle EMG analysis of the MUP "Thickness" and proposal of "size index".** *Electroencephalogr Clin Neurophysiol* 89: 291-303, 1993.

SPITIZER, A.R.; WANG, C.; HASSOUN, M.H. **Digital filtering of the EMG for automated EMG decomposition.** *Muscle & Nerve* 12: 779-780, 1989.

EESC-USP Biblioteca CAMPUS DE S. CARLOS

STALBERG, E.; ANDREASSEN, S.; FALCK, B.; LANG, H.; ROSENFALCK, A.; TROJABORG, W. **Quantitative analysis of individual motor unit potentials: a proposition for standardized terminology and criteria for measurement.** *Journal of Clinical Neurophysiology* 3:313-348; 1986.

STALBERG, E.V.; NANDEDKAR, S.D.; SANDERS, D.B.; FALCK, B. **Quantitative motor unit potential analysis.** *J Clin Neurophysiol* 13: 401-422, 1996.

STALBERG, E.V.; SONOO, M. **Assesment of varibility in the shape of the motor unit action potential, the "jiggle" at consecutive discharges.** *Muscle & Nerve* 17: 1135-1144, 1994.

STASHUK, D.; DE BRUIN, H. **Automatic decomposition of seletive needle-detected myoeletric signal.** *IEEE Trans Biomed Eng* 35: 1-10, 1988.

STASHUK, D.W. **Decomposition and quantitative analysis of clinical electromyographic signals.** *Med. Eng. Phys.* 21: 389-404, 1999.

STASHUK, D.W. **EMG signal decomposition: how can it be accomplished and used?** *Journal Of Electromyography And Kinesiology,* 11: 151-173, 2001.

STASHUK, D.W.; QU, Y. **Adaptative motor unit action potential clustering using shape and temporal information.** *Med. Biol. Eng. Comput., 34:41-49, 1996.*

SUN, T.; CHEN, J.; LIN, T. **Analysis of motor unit firing patterns in patients with central or peripheral lesions using singular-value Decomposition.** *Muscle & Nerve,* 1057-1068, 2000 (July).

ULTSCH, A. **Knowledge Extraction from Self-Organizing Neural Networks.** In: O. Opitz et al. (Eds). *Information and Classification.* Springer, Berlin, 301-306, 1993a.

ULTSCH, A. **Self-Organizing Neural Networks for Visualization and Classification.** In: O. Opitz et al. (Eds). *Information and Classification.* Springer, Berlin, 307-313, 1993b.

USUI, S; AMIDOR, I. **Digital low-pass differentiation for biological signal processing.** *IEEE Trans Biomed Eng* 29: 686-693, 1982.

VAN, STEENWIJK.R. **Concept of local resolution in the design of lead off electrode systems.** *Med Biol. Eng. Comput.* 24: 616-624, 1986.

XU, Z.Q.; XIAO, S.J.; CHI Z.R. **ART2 neural network for surface EMG decomposition.** *Neural Computing & Applications,* 10: 29-38, 2001.

SUGESTÕES PARA TRABALHOS FUTUROS

A continuidade desse trabalho pode aprofundar as pesquisas no sentido de aprimorar o esquema de processamento desenvolvido. Assim sendo apresentam-se algumas sugestões:

1. Estudo visando o aprimoramento do procedimento de classificação, buscando utilizar conjuntamente a informação temporal dos MUAPs com a informação de forma, isto aumentaria sobremaneira a eficácia do processo de classificação;

2. Elaboração de um algoritmo para resolução de superposições, observando que este não venha comprometer demasiadamente o custo computacional;

3. Estudo de metodologia para determinação automatizada de parâmetros nos diversos procedimentos desenvolvidos nesta pesquisa, objetivando a aplicação clínica;

4. Realização de testes e nova aquisição de sinais usando eletrodos NDD, que devem ser especialmente construídos para esse fim;

5. Estudo comparativo da decomposição, realizada usando os sinais adquiridos com o eletrodo NDD, comparando-se os resultados obtidos em relação aos eletrodos diferenciais convencionais;

6. Os padrões de disparos caracterizados pelos histogramas de IPI também refletem mudanças patológicas nas UMs, e deveriam ser investigados quanto à produção de diagnósticos e avaliação de mudanças fisiopatológicas neuromusculares, servindo como um recurso complementar no processo de tomada de decisão pelo clínico. As características de modulação da taxa de disparo, obtidas

do processo de decomposição, podem ser associadas aos estados neurofisiológicos da UM, conforme têm mostrado diversos trabalhos recentes (Fang J. et al., 1997), (Disslhorst-Klug C. et al., 1998), (Pattichis C.S. & Elia AG., 1999), (Sun, T. et al., 2000), informações estas que são de bastante interesse do ponto de vista clínico, e tem valor adicional no planejamento e avaliação de tratamento em pacientes com deficiências funcionais do músculo.

7. Trabalhos futuros poderiam investigar a interpretação dos coeficientes AR e cepstral em relação às mudanças fisiopatológicas musculares como: velocidade de propagação do MUAP, velocidade de dispersão, tamanho da zona de inervação, localização do eletrodo, número de fibras na unidade motora, etc. A análise wavelet motiva por suas características especiais a aplicação na análise de MUAPs, e poderia ser investigada também quanto a produção de diagnósticos.