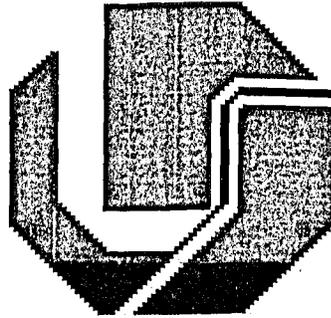


UNIVERSIDADE FEDERAL DE UBERLÂNDIA
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

11011
621.3
A553m
TES / M.EM



DIRBI/UFU



1000190166

Metodologia para Classificação de Sinais EMG no Controle de Membros Artificiais

Adriano de Oliveira Andrade

Janeiro

2000

21510

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Metodologia para Classificação de Sinais EMG no Controle de Membros Artificiais

Adriano de Oliveira Andrade[‡]

Texto da dissertação apresentada à Universidade Federal de Uberlândia, perante a banca de examinadores abaixo, como parte dos requisitos necessários para a obtenção do título de Mestre em Engenharia Elétrica. Aprovada em 19 de Janeiro de 2000.

Banca Examinadora:

Alcimar Barbosa Soares, PhD - Orientador (UFU)

Raimes Moraes, PhD (UFSC)

José Manoel Fernandes, PhD (UFU)

Luciano Vieira Lima, Dr. (UFU)

[‡]A bolsa de estudo para esta pesquisa foi concedida pela CAPES, Brasil.

Metodologia para Classificação de Sinais EMG no Controle de Membros Artificiais

Adriano de Oliveira Andrade[§]

Texto da dissertação apresentada à Universidade Federal de Uberlândia como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica.

Prof. Alcimar Barbosa Soares, Ph.D.
Orientador

Prof. Darizon Alves de Andrade, Ph.D.
Coordenador do curso de Pós-Graduação

[§]A bolsa de estudo para esta pesquisa foi concedida pela CAPES, Brasil.

*Aos meus pais Walter e Jasiva,
À minha irmã Tatiana (Tati),
pelo incentivo e apoio durante minha jornada.*

Agradecimentos

À SOTELGO que em nome do Naldo, Ronaldo e Gustavo forneceu apoio para a concretização do meu mestrado.

Ao Valter, Dirce e seus familiares por terem tornado minha estadia em Uberlândia mais prazerosa.

Ao Fábio Lemos pela ajuda no momento certo.

Ao Gonçalo e à Joana pela amizade e o auxílio na secretaria de pós-graduação.

Aos meus amigos de laboratório: Cleber, Marcelle, Eduardo e Manço que, além de ajuda, me trouxeram muito conhecimento.

Ao meu amigo Anderson, companheiro de enormes caminhadas.

Aos meus pacientes (Gisele, Marcos, Denise, Eduardo e Letícia) que suportaram realizar quatro horas consecutivas de experimentos. Vocês realmente têm um bom preparo!!!

À professora Edna pela troca de conhecimentos e pela amizade.

Ao professor Darizon pelo ótimo trabalho que vem realizando na coordenação do curso de pós-graduação e por ter generosamente cedido a placa de aquisição de dados, essencial à realização deste trabalho.

Ao professor Alcimar por ter realizado, com sucesso, a arte de orientar e ainda por ter sido amigo e companheiro.

A todos aqueles que contribuíram de alguma forma, direta ou indiretamente, para a realização deste trabalho.

À CAPES por ter concedido suporte financeiro a esta pesquisa.

E a Deus por estar sempre presente em minha vida.

Resumo

Andrade, Adriano de O. Metodologia para Classificação de Sinais EMG no Controle de Membros Artificiais, Uberlândia, DEENE-UFU, 2000, 105p.

Um dos grandes desafios atuais das pesquisas envolvendo o aperfeiçoamento de membros artificiais, é que esses possam ser controlados de maneira mais natural possível pelos pacientes. Neste sentido, os processos envolvendo a aquisição e a manipulação das informações de controle provenientes do paciente, têm merecido especial atenção. Dentre as diversas técnicas de controle possíveis, uma das que tem alcançado melhores resultados utiliza a atividade eletromiográfica resultante de contrações voluntárias de determinados grupos musculares.

Numa tentativa de contribuir para aquelas pesquisas, foi desenvolvido um sistema de processamento de sinais eletromiográficos (EMG), capaz de fornecer entradas de controle para uma prótese com quatro graus de liberdade. Para tal, sinais EMG provenientes dos grupos musculares tríceps e bíceps foram classificados em quatro padrões distintos: flexão e extensão do cotovelo, pronação e supinação do punho. A classificação dos padrões foi feita através de uma rede neural artificial que recebe como entrada as características dos sinais eletromiográficos, extraídas através de um modelo autoregressivo.

Outro objetivo desta pesquisa foi buscar o número mínimo de pares de eletrodos e os sítios mais adequados para a detecção, processamento e classificação satisfatória dos movimentos executados. Foram feitas análises considerando 5 pares de eletrodos, sendo dois sobre o bíceps - na cabeça longa (B1) e na cabeça curta (B2) - e três sobre o tríceps - na

cabeça longa (T1), na cabeça medial (T2) e na cabeça lateral (T3); e um par de eletrodos sobre o plexo braquial. Os experimentos foram realizados considerando-se contrações isométricas e isotônicas. Aqueles sinais foram analisados em diversas combinações, para cada tipo de contração, numa tentativa de se encontrar aquela que apresentasse melhores resultados. Os resultados mostraram que as combinações envolvendo o uso de dois pares de eletrodos posicionados sobre os sítios B2 e T1; e três pares de eletrodos posicionados sobre os sítios B2, T1 e T2 ou B2, T1 e T3 apresentaram melhores performances, com taxas de acerto de até 100%.

Palavras-chave

Eletromiografia, redes neurais, modelo autoregressivo, prótese.

Abstract

Andrade, Adriano de O. EMG Pattern Recognition For Prosthesis Control, Uberlândia, DEENE-UFU, 2000, 105p.

One of the major challenges for prosthesis development is to produce devices which mimic their natural counterparts. In general, artificial limbs don't have proper feedback by which the user can assess the status of the prosthesis and the control is very unnatural. Preferably, a subconscious control is desired. Myoelectric control has been widely used as an alternative strategy designed for easier control. However, there is still a lot to be done in order to achieve artificial limbs as dextrous as human limbs.

In an attempt to contribute to the researches towards better artificial limbs, it has been developed an EMG processing system, capable of generate input control to a four degrees of freedom prosthesis. Two major muscle groups (biceps and triceps) were used as source of electromyographic signals, which were discriminated into four different classes: elbow flexion, elbow extension, wrist pronation and wrist supination. Those patterns were classified by an artificial neural network, which received as inputs the EMG signal features extracted by an autoregressive model.

The minimum number of pairs of electrodes and their best positioning for detection, processing and classification were also investigated. To do so, five pairs of electrodes (two on the biceps - long head (B1) and short head (B2) - and three on the triceps - long head (T1), medium head (T2) and lateral head(T3)) and one pair of electrodes (on plexo brachial) configuration were considered. Isometric and isotonic contractions were

analyzed for each one of those two configurations. The EMG signals were studied in several combinations for each type of contraction. The results show that the configurations using two pairs of electrodes (positioned on B2 and T1) and three pairs of electrodes (positioned on B2, T1 and T2 or B2, T1 and T3), provided accuracy as good as 100%, for the EMG pattern recognition process.

Keywords

Eletromiography, neural networks, autoregressive model, prosthesis.

Conteúdo

1	Introdução	1
1.1	Motivação para o Trabalho	1
1.2	O Estado da Arte e Algumas Pesquisas para Processamento de Sinais EMG	3
1.3	Objetivos do Trabalho	5
1.4	Estrutura da Dissertação	6
2	Próteses de Membros Artificiais	7
2.1	Introdução	7
2.2	Próteses Atuais - Tipos e Funções	8
2.2.1	Próteses Passivas	8
2.2.2	Próteses Energizadas pelo Corpo	9
2.2.3	Próteses Energizadas por Unidades Externas	9
2.2.4	Próteses Híbridas	10
2.3	Estratégias de Controle	10
2.3.1	Sistema de Arreios	11
2.3.2	Controle Mioelétrico	11
2.3.3	Controle Neuroelétrico	13
2.3.4	Realimentação Sensorial	14
2.4	Conclusão	16
3	Processamento de Sinais Eletromiográficos	17
3.1	Introdução	17

3.2	Fisiologia da Contração Muscular	18
3.3	O Sinal Eletromiográfico	18
3.4	Análise no domínio do tempo	19
3.4.1	Introdução à terminologia	19
3.4.2	Medidas das propriedades do sinal	21
3.4.3	Análise de Séries Temporais - Conceitos Gerais	21
3.5	Extração de Características - O Modelo Autoregressivo	26
3.5.1	Cálculo dos Parâmetros do Modelo Autoregressivo	28
3.5.2	Determinação da Ordem do Modelo Autoregressivo	30
3.6	Classificação de Padrões	31
3.7	Conclusão	38
4	Descrição do Sistema Desenvolvido	39
4.1	Introdução	39
4.2	Características Desejáveis para os Estágios	40
4.2.1	Estágio de Detecção	40
4.2.2	Estágio de Condicionamento	43
4.2.3	Estágio de Aquisição	45
4.2.4	Estágio de Janelamento	45
4.2.5	Estágio de Extração das Características	46
4.2.6	Estágio de Classificação	46
4.3	Características do Sistema Desenvolvido	46
4.3.1	Detecção	46
4.3.2	Condicionamento	47
4.3.3	Aquisição	49
4.3.4	Janelamento	51
4.3.5	Extração das Características	52
4.3.6	Classificação	54
4.4	Conclusão	55

5 Experimentos e Resultados	56
5.1 Introdução	56
5.2 Descrição da Metodologia Experimental	58
5.3 Apresentação e Discussão dos Resultados	63
5.4 Conclusão	93
6 Conclusão e Trabalhos Futuros	94
6.1 Conclusões Gerais	94
6.2 Trabalhos Futuros	99
Bibliografia	101

Lista de Figuras

2.1	Procedimento de cineplastia.	8
2.2	Prótese passiva.	9
2.3	Prótese <i>Body-Powered</i>	9
2.4	Exemplo de uma prótese energizada por unidades externas. Observe que a parte mecânica da prótese pode ser controlada através da atividade eletromiográfica.	10
2.5	Prótese mioelétrica atual.	12
2.6	Soquete para um braço e eletrodos para uma prótese mioelétrica.	12
2.7	Prótese neuroelétrica.	14
2.8	Diagrama de um sistema homem-prótese mostrando possíveis caminhos de informações.	15
3.1	Sinal eletromiográfico proveniente de uma contração isométrica do tríceps (cabeça medial). O sinal foi amplificado 4400 vezes e adquirido a uma frequência de 5 kHz.	18
3.2	(a) Formas de onda defasadas. (b) Forma de onda x_2 deslocada de j atrasos à esquerda de x_1	23
3.3	Pares de formas de ondas $\{x_1(n), x_2(n)\}$, $\{x_3(n), x_4(n)\}$, de diferentes amplitudes.	24
3.4	Função auto-correlação de uma forma de onda randômica.	25
3.5	Estimador linear adaptativo.	29
3.6	Modelo para classificação de padrões.	32

3.7	Representação do neurônio biológico e da seqüência de transmissão de impulsos.	33
3.8	Intervalos de tempo característicos em decorrência do potencial de ação no axônio. T_n é o período da geração do potencial de ação, T_a é o período de refração absoluta e T_r é o período de refração relativa.	34
3.9	Modelo de neurônio.	35
3.10	Uma rede neural simples.	35
3.11	Arquitetura de uma rede neural MLP com uma camada escondida.	37
3.12	(a) Função sigmóide bipolar: $f(x) = \frac{2}{1+e^{-x}} - 1$. (b) Função sigmóide binária: $f(x) = \frac{1}{1+e^{-x}}$	38
4.1	Sistema de processamento e classificação de sinais EMG.	40
4.2	Estágio pré-amplificador em eletrodos ativos. (a) Diagrama de um circuito diferencial duplo utilizado na pré-amplificação. (b) Sinais EMG detectados por eletrodos ativos.	41
4.3	Eletrodos intramusculares baseados em agulha e fio.	41
4.4	Projeto de superfícies de apoio para a fixação de eletrodos. (a) Projeto para eletrodo de raio 5.5 mm. (b) Projeto para eletrodo de raio 4.75 mm. (c) Projeto para eletrodo de referência de raio 4.75mm.	47
4.5	Eletrodos de disco antes e após a fixação sobre as superfícies projetadas.	47
4.6	Foto do sistema para condicionamento de sinais utilizado nos experimentos.	48
4.7	Diagrama de Bode para o canal 0 (CH0) do eletromiógrafo.	49
4.8	Interface principal para controle da aquisição, visualização e armazenamento de sinais.	50
4.9	Ferramenta <i>Zoom</i>	51
4.10	Tela de apresentação da Ferramenta Matemática Básica.	51
4.11	Interface gráfica de janelamento de sinais EMG.	52
4.12	Interface gráfica do programa para extração de características.	53

4.13	(a) Sinal estimado com base no LMS tradicional. Observe através do <i>zoom</i> a diferença entre os sinais de entrada e o estimado. (b) Sinal estimado com base no LMS modificado. Observe através do <i>zoom</i> a semelhança entre os sinais de entrada e o estimado.	54
4.14	Arquitetura neural MLP utilizada.	55
5.1	Estrutura do grupo experimental.	56
5.2	Posicionamento dos cinco pares de eletrodos sobre as cabeças do bíceps e do tríceps.	57
5.3	Detalhe do posicionamento de par de eletrodos sobre o plexo braquial. . . .	57
5.4	Posicionamento do eletrodo de referência sobre o ombro.	58
5.5	Projeto de aparato experimental para aquisição de sinais provenientes de contrações isométricas.	59
5.6	Contrações isotônicas (Calais-German, 1991) [2]. (a) Movimentos de flexão e extensão dos cotovelos. (b) Movimento de supinação do punho. (c) Movimento de pronação do punho.	60
5.7	Superfície AR com (3x5) coeficientes para o grupo Isotônico - cinco pares. . . .	65
5.8	Superfície AR com (4x5) coeficientes para o grupo Isotônico - cinco pares. . .	65
5.9	Superfície AR com (6x5) coeficientes para o grupo Isotônico - cinco pares. .	66
5.10	Superfície AR com (8x5) coeficientes para o grupo Isotônico - cinco pares. . . .	66
5.11	Superfície AR com (10x5) coeficientes para o grupo Isotônico - cinco pares. .	67
5.12	Superfície AR com 3 coeficientes para o grupo Isotônico - um par.	68
5.13	Superfície AR com 4 coeficientes para o grupo Isotônico - um par.	68
5.14	Superfície AR com 6 coeficientes para o grupo Isotônico - um par.	69
5.15	Superfície AR com 8 coeficientes para o grupo Isotônico - um par.	69
5.16	Superfície AR com 10 coeficientes para o grupo Isotônico - um par.	70
5.17	Superfície AR com (3x5) coeficientes para o grupo Isométrico - cinco pares. .	71
5.18	Superfície AR com (4x5) coeficientes para o grupo Isométrico - cinco pares. . .	71
5.19	Superfície AR com (6x5) coeficientes para o grupo Isométrico - cinco pares. .	72
5.20	Superfície AR com (8x5) coeficientes para o grupo Isométrico - cinco pares. .	72

5.21	Superfície AR com (10x5) coeficientes para o grupo Isométrico - cinco pares. . .	73
5.22	Superfície AR com 3 coeficientes para o grupo Isométrico - um par.	74
5.23	Superfície AR com 4 coeficientes para o grupo Isométrico - um par.	74
5.24	Superfície AR com 6 coeficientes para o grupo Isométrico - um par.	75
5.25	Superfície AR com 8 coeficientes para o grupo Isométrico - um par.	75
5.26	Superfície AR com 10 coeficientes para o grupo Isométrico - um par.	76

Lista de Tabelas

5.1	Valores de <i>scale</i> e <i>offset</i> para os grupos experimentais.	61
5.2	Representação dos vetores alvos. V1 representa o alvo para a classe de extensão, V2 para a classe de flexão, V3 para a classe de supinação e V4 para a classe de pronação.	63
5.3	Grupo de Treinamento - Isotônico - 5 pares	77
5.4	Grupo de Execução - Isotônico - 5 pares	77
5.5	Grupo de Treinamento - Isométrico - 5 pares	78
5.6	Grupo de Execução - Isométrico - 5 pares	78
5.7	Grupo de Treinamento - Isotônico - 1 par	79
5.8	Grupo de Execução - Isotônico - 1 par	79
5.9	Grupo de Treinamento - Isométrico - 1 par	80
5.10	Grupo de Execução - Isométrico - 1 par	80
5.11	Grupo de Treinamento - Isotônico - B1T1	81
5.12	Grupo de Execução - Isotônico - B1T1	81
5.13	Grupo de Treinamento - Isométrico - B1T1	81
5.14	Grupo de Execução - Isométrico - B1T1	82
5.15	Grupo de Treinamento - Isotônico - B1T2	82
5.16	Grupo de Execução - Isotônico - B1T2	83
5.17	Grupo de Treinamento - Isométrico - B1T2	83
5.18	Grupo de Execução - Isométrico - B1T2	83
5.19	Grupo de Treinamento - Isotônico - B1T3	84
5.20	Grupo de Execução - Isotônico - B1T3	84

5.21	Grupo de Treinamento - Isométrico - B1T3	85
5.22	Grupo de Execução - Isométrico - B1T3	85
5.23	Grupo de Treinamento - Isotônico - B2T1	86
5.24	Grupo de Execução - Isotônico - B2T1	86
5.25	Grupo de Treinamento - Isométrico - B2T1	86
5.26	Grupo de Execução - Isométrico - B2T1	87
5.27	Grupo de Treinamento - Isotônico - B2T2	87
5.28	Grupo de Execução - Isotônico - B2T2	88
5.29	Grupo de Treinamento - Isométrico - B2T2	88
5.30	Grupo de Execução - Isométrico - B2T2	88
5.31	Grupo de Treinamento - Isotônico - B2T3	89
5.32	Grupo de Execução - Isotônico - B2T3	89
5.33	Grupo de Treinamento - Isométrico - B2T3	89
5.34	Grupo de Execução - Isométrico - B2T3	90
5.35	Grupo de Treinamento - Isotônico - B2T1T2	90
5.36	Grupo de Execução - Isotônico - B2T1T2	91
5.37	Grupo de Treinamento - Isométrico - B2T1T2	91
5.38	Grupo de Execução - Isométrico - B2T1T2	91
5.39	Grupo de Treinamento - Isotônico - B2T1T3	92
5.40	Grupo de Execução - Isotônico - B2T1T3	92
5.41	Grupo de Treinamento - Isométrico - B2T1T3	92
5.42	Grupo de Execução - Isométrico - B2T1T3	93
6.1	Resultados para 5 pares de eletrodos.	97
6.2	Resultados para combinações de pares de eletrodos e 6 coeficientes AR. . .	97
6.3	Resultados para 1 par de eletrodos.	98

Capítulo 1

Introdução

1.1 Motivação para o Trabalho

O corpo humano sempre foi considerado uma máquina perfeita, em que todas as partes trabalham em harmonia umas com as outras. A maioria de nós pode controlar esta “máquina” sem muito esforço, até que algum distúrbio provocado por alguma doença ou lesão resulte na perda de algumas de suas funcionalidades.

A ausência de membros causada por traumas ou distúrbios congênitos, pode afetar nossas vidas profundamente. Tarefas simples como caminhar ou vestir-se podem se tornar extremamente difíceis ou até impossíveis de serem executadas. Não há dúvida que a melhor solução para a perda de um membro é o desenvolvimento de alguma espécie de manipulação genética que estimule a regeneração do mesmo. Contudo, enquanto isto ainda não é possível, o melhor que podemos fazer é restabelecer parte da funcionalidade perdida através de membros artificiais.

Já no início deste século discutiam-se as possibilidades de mãos biônicas. Wolfe (Childress, 1973) [3] em 1952 descreveu em seu livro de ficção-científica, *New York: Random House*, algumas previsões sobre atividades cibernéticas possíveis em 1990. Uma delas é descrita a seguir:

“... They had perfected an artificial limb superior in many ways to the real thing, integrated into the nerves and muscles of the stump, powered by a built-

in atomic energy plant, equipped with sensory as well as motor functions..."

Tal previsão não se concretizou, mas muito tem sido feito desde então.

Devido às casualidades provocadas pela Segunda Guerra Mundial, os Estados Unidos, criaram em 1945 um programa de pesquisa e desenvolvimento em que cientistas e engenheiros norte-americanos se envolveram profundamente em projetos visando a substituição de membros amputados por membros artificiais.

Um outro fato que provocou uma aceleração das pesquisas na área foi o grande número de deficiências congênitas provocadas pelo uso de uma droga chamada Talidomida. Ela foi sintetizada pelo laboratório alemão Chemie Grünenthal em 1957 e comercializada em todo o mundo entre 1958 e 1962. Esta droga era prescrita para minimizar enjoos durante a gravidez. As consumidoras da Talidomida não foram advertidas de que a droga poderia ultrapassar a placenta, afetando o feto. Essa inadvertência teve um efeito catastrófico: o consumo da droga, principalmente durante o primeiro trimestre de gravidez, provocou a morte de milhares de bebês. Os que sobreviveram tiveram defeitos de nascença tais como surdez, cegueira, desfiguramento e principalmente o encurtamento ou a ausência de membros. Diversos centros de pesquisa intensificaram então seus esforços em projetos de membros artificiais para tentar melhorar a vida daquelas crianças.

Neste mesmo período, cientistas russos introduziram uma prótese de uma mão controlada através de sinais detectados pelas atividades de músculos remanescentes de membros amputados. Esse controle, denominado "controle mioelétrico", surgiu na Alemanha por volta de 1945 e já vinha sendo investigado em vários países, mas até então não havia sido criado nenhum sistema comercial.

Atualmente, as pesquisas no aperfeiçoamento de membros protéticos estão voltadas a atender o significado clínico do uso desses membros, ou seja, um membro protético deve ser prescrito para o paciente, comprado para ou pelo paciente, e adequado ao mesmo. Deve-se observar ainda que o treinamento e a manutenção do membro possam ser realizados pelo paciente sem que isso exija um esforço muito grande, possibilitando-lhe controlar a prótese do modo mais natural possível.

O controle das próteses atuais baseia-se principalmente na análise de duas classes de

fontes de sinais: biomecânica e bioelétrica. Na biomecânica são considerados estudos sobre o movimento de partes do corpo, as alterações nas propriedades de um componente do corpo como resultado de uma atividade mecânica e o controle do fluxo de ar. Já na bioelétrica são analisados sinais elétricos resultantes de atividades musculares, cerebrais, neurais e oculares.

1.2 O Estado da Arte e Algumas Pesquisas para Processamento de Sinais EMG

O processamento de sinais eletromiográficos aplicado ao controle de membros artificiais tem sido assunto de diversas pesquisas. Graupe *et al.* (1975) [4] demonstraram que as propriedades espectrais do sinal EMG modificam-se de acordo com as diferentes funções executadas pelos membros. O espectro de cada classe da função do membro foi definido utilizando um modelo autoregressivo (AR). O sistema descrito por eles permite controlar cinco funções de um membro, em tempo real. A discriminação de uma dada função do membro foi completada aproximadamente 0,2 segundos após a iniciação daquela função.

Doerschuk *et al.* (1983) [43] utilizaram a análise de sinais EMG para realizar a discriminação de funções de membros superiores. Os dados para essa análise foram obtidos a partir de quatro eletrodos localizados em torno do antebraço. Neste trabalho, o sinal EMG foi analisado como um processo estocástico levando-se em conta a forma espectral do sinal e a interferência produzida entre canais. Para cada função dos membros, foram calculados modelos autoregressivos.

Hefftner *et al.* (1988) [19] utilizaram a eletromiografia como sinal de controle para a estimulação funcional neuromuscular. Neste trabalho os conceitos relativos à séries-temporais são descritos e a possibilidade de utilização do processamento de sinais EMG através desse método é investigada. O eletromiograma, o qual exibe uma fraca estacionaridade durante pequenos intervalos de tempo, é representado por um modelo AR de quarta ordem. Um algoritmo seqüencial de mínimos quadrados foi utilizado para determinar os parâmetros do modelo, os quais são utilizados como características do sinal para

sua discriminação. Como conclusão, notou-se que o modelamento do sinal EMG através do modelo AR é apropriado, pois o método se mostrou confiável para detecção e identificação das diferenças nas características do sinal eletromiográfico. A versatilidade do método é demonstrada pelo fato de que ele não é limitado a localizações específicas de eletrodos e pode ser modificado de acordo com as necessidades de cada problema, por exemplo, o nível da lesão, a força dos músculos ativos e o grau de controle sobre esses músculos.

Gunawardana (1995) [12] utilizou sinais mioelétricos para determinar a função executada por uma mão protética. O sinal foi modelado como um processo AR e os seus coeficientes foram utilizados como características para a classificação das funções das mãos. A extração dos coeficientes do modelo AR foi feita utilizando-se a rede neural de Hopfield. A classificação do sinal foi realizada utilizando-se um classificador de Bayes e uma rede neural multicamadas. Gunawardana (1995) [12] observou que quatro funções da mão puderam ser classificadas em tempo real com uma precisão de 90% para o classificador bayesiano e de 80% para a rede neural.

Como pode ser observado, a maioria das pesquisas relacionadas ao processamento do sinal EMG o considera estacionário, apesar de ser globalmente não-estacionário. A ausência de métodos mais eficientes para o processamento de sinais não-estacionários pode ser considerado como um fator relevante que justificaria a análise estacionária do sinal EMG. Contudo, Xiong & Shwedyk (1987) [39] fizeram uma análise do sinal EMG considerando-o como um processo não-estacionário. Eles utilizaram um estimador MMAE (*Midpoint Moving Average Estimator*) para compensar a não-estacionaridade do sinal. A performance do estimador foi avaliada tanto em sinais EMG simulados, quanto em reais e comparada com métodos padrões de processamento de sinais EMG. Os resultados obtidos foram aceitáveis com um erro variando entre 2% a 3% em relação a estes métodos.

Além dos métodos AR, a análise estatística também tem sido muito utilizada para compreender o comportamento dos sinais EMG. Merletti & Conte (1995a, 1995b) [5] [6] introduziram algumas técnicas, revisaram e compararam diferentes métodos de analisar sinais EMG e discutiram suas aplicações e limitações. A conclusão desse trabalho foi que

diferentes métodos usados para estimar os mesmos parâmetros, ou variáveis, fornecem diferentes resultados. Como consequência, é importante definir claramente os parâmetros de interesse do sinal e utilizar o algoritmo mais apropriado para o objetivo desejado, tendo-se plena consciência de suas vantagens, limitações e implicações fisiológicas.

Outra estratégia para a classificação de sinais EMG foi descrita por Hudgins *et al.* (1993) [36]. Eles mostraram que no sinal EMG, coletado por um par de eletrodos bipolares, existe um conjunto de componentes determinísticas durante a fase inicial da contração muscular. Uma vez que essas componentes não randômicas foram detectadas, uma rede neural artificial foi utilizada como classificador. A rede neural foi treinada para reconhecer a importância relativa de cinco características usadas para representar o padrão mioelétrico: tendência do valor médio absoluto, cruzamentos por zero, trocas de sinal da derivada e comprimento da forma de onda. Hudgins *et al.* (1993) [36] observaram que a rede neural foi capaz de classificar contrações, apresentadas depois do treinamento, em quatro categorias (flexão do cotovelo, extensão do cotovelo, pronação e supinação) com uma precisão variando de 70% a 98%. Desenvolvimentos posteriores dessa pesquisa (Kunganti *et al.*, 1995) [38] aumentaram a precisão de classificação para uma faixa variando de 83% a 100%, usando dois pares de eletrodos pouco espaçados, porém usando somente duas das cinco características originais (valor médio absoluto e cruzamentos por zero).

Geralmente os métodos descritos envolvem um grande número de cálculos e conseqüentemente um alto consumo do tempo e equipamentos, razoavelmente, complexos para executá-los. Essa é a principal razão pela qual muitas dessas técnicas ainda não alcançaram aplicações clínicas. Contudo, com o rápido desenvolvimento da indústria eletrônica, é esperado que todo o potencial das mesmas possa ser aplicado em um futuro próximo.

1.3 Objetivos do Trabalho

Conforme mencionado, um dos grandes desafios para o controle de próteses é que isto seja feito com um mínimo esforço e de modo natural. Neste sentido, o presente trabalho tem como principais objetivos:

- Investigar o estado da arte das principais técnicas para controle de próteses de membros superiores;
- Analisar métodos de extração e classificação de características de sinais eletromiográficos (EMG);
- Propor e avaliar um modelo de um sistema de processamento e classificação de sinais eletromiográficos aplicado ao controle de próteses;
- Sugerir estudos futuros que possam ser realizados a partir do trabalho desenvolvido.

1.4 Estrutura da Dissertação

A estratégia utilizada para atingir os objetivos acima está descrita em cada um dos capítulos deste trabalho. Estruturalmente este texto está dividido da seguinte forma:

- Capítulo 1: Apresentação da motivação, dos objetivos e da estrutura do trabalho;
- Capítulo 2: Investigação do estado da arte das principais técnicas para o controle de próteses de membros superiores;
- Capítulo 3: Investigação de métodos tradicionais para extração e classificação de características de sinais eletromiográficos;
- Capítulo 4: Um modelo de sistema de processamento e classificação de sinais eletromiográficos é proposto;
- Capítulo 5: O modelo apresentado no Capítulo 4 é avaliado. São apresentados os resultados e a metodologia adotada nos experimentos e na avaliação;
- Capítulo 6: Finalmente, são expostas as conclusões finais relevantes desse trabalho, bem como as sugestões para trabalhos futuros que podem ser realizados a partir do mesmo.

Capítulo 2

Próteses de Membros Artificiais

2.1 Introdução

Há vários séculos, o homem procura formas de substituir membros perdidos por artefatos mecânicos. Várias próteses antigas podem ser encontradas em museus e bibliotecas. Contudo, o primeiro artefato a ser formalmente denominado membro artificial foi uma prótese romana, constituída de madeira e bronze, surgida aproximadamente em 300 AC (Lamb & Law, 1987) [24].

Durante a idade média, enquanto pobres usavam “pernas de madeira” - simples, baratas e estáveis - os nobres e ricos utilizavam dispositivos feitos de ferro, que além de funcionais eram ainda decorativos.

Ambroise Paré (1510 - 1590), um dos mais célebres cirurgiões do século XVI, inventou e exibiu inúmeras pernas, mãos e braços artificiais consideravelmente complexos para a época.

Até 1818, quando Peter Ballif projetou a primeira prótese *Body-Powered**, as próteses de membros superiores eram pesadas e dependiam de uma mão sadia para operação. O projeto de Ballif utilizou movimentos da escápula e da clavícula para controlar a prótese, porém este modelo só podia ser utilizado em casos de amputação do antebraço. Em 1844 Van Peetersen utilizou o mesmo princípio para projetar um sistema de flexão do cotovelo.

*Prótese acionada por movimentos de partes saudáveis do corpo.

Em 1855 Beafort demonstrou um braço com a flexão do cotovelo operada pela pressão de uma alavanca sobre o peito.

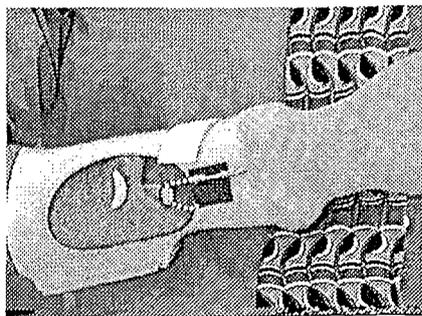


Figura 2.1: Procedimento de cineplastia.

dendo levá-los a ruptura.

Atualmente, os dispositivos protéticos podem ser subdivididos em quatro classes, levando-se em consideração se a prótese possui ou não articulação ativa e a energia utilizada para gerar os movimentos requeridos:

- Próteses Passivas
- Próteses energizadas pelo corpo (Próteses *Body-Powered*)
- Próteses energizadas por unidades externas (Próteses *Externally-Powered*)
- Próteses Híbridas

As seções seguintes descrevem cada um desses tipos de próteses bem como suas técnicas de controle.

2.2 Próteses Atuais - Tipos e Funções

2.2.1 Próteses Passivas

As próteses passivas podem ser completamente imóveis e muitas vezes são utilizadas somente por razões estéticas, como mostrado na Figura 2.2. No caso de próteses passivas

[†]Procedimento cirúrgico onde um túnel é formado no músculo.

móveis, suas articulações podem ser movidas e colocadas nas posições desejadas através de forças externas.

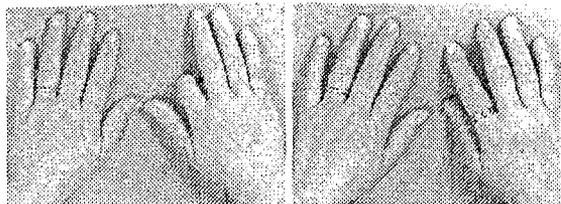


Figura 2.2: Prótese passiva.

2.2.2 Próteses Energizadas pelo Corpo

Este tipo de prótese é operada de tal maneira que a força do movimento de uma parte do corpo reflita na execução de movimentos da prótese. A Figura 2.3 ilustra uma prótese *Body-Powered* que pode ser controlada através de movimentos do ombro. Observe que o sistema de “arreios”, além de fixar a prótese ao membro amputado, serve de apoio para o movimento a ser executado.

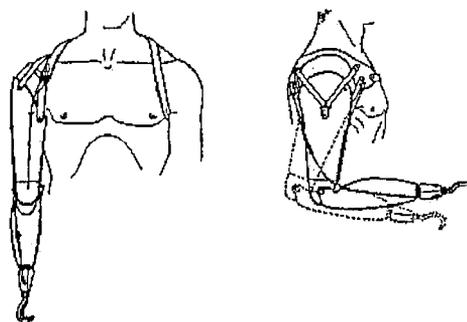


Figura 2.3: Prótese *Body-Powered*.

2.2.3 Próteses Energizadas por Unidades Externas

Em certas situações, e de acordo com as necessidades do paciente, é recomendado que a prótese seja energizada por alguma fonte externa de energia. Atualmente, a fonte mais comum de energia são baterias. Estas próteses são controladas normalmente pelo movimento de estruturas naturais remanescentes ou através da atividade eletromiográfica fornecida por um grupo muscular escolhido. Um exemplo de prótese energizada por unidades externas é mostrado na Figura 2.4.

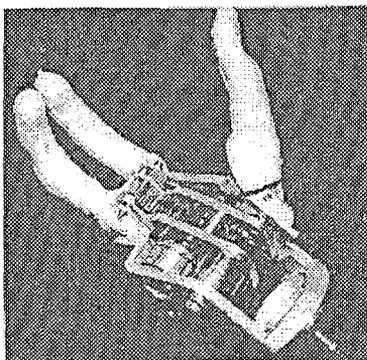


Figura 2.4: Exemplo de uma prótese energizada por unidades externas. Observe que a parte mecânica da prótese pode ser controlada através da atividade eletromiográfica.

2.2.4 Próteses Híbridas

Em amputações de membros superiores, tais como amputações acima do cotovelo, o controle miolétrico para as funções da mão pode ser combinado com um sistema de controle através de “arreios” para as funções do cotovelo. Esse tipo de prótese é conhecido como prótese híbrida, pois combina dois tipos de controle na mesma prótese.

2.3 Estratégias de Controle

O controle de próteses pode ser considerado um dos assuntos mais interessantes em relação ao desenvolvimento protético. Idealmente, uma prótese deve ser controlada sem que isso exija qualquer esforço do usuário e ainda seja similar ao controle subconsciente de um membro natural. As principais estratégias utilizadas atualmente para controle de membros artificiais superiores são: o sistema de “arreios” e o controle mioelétrico.

Existem ainda, pesquisas em andamento buscando outras formas de controle mais naturais, como por exemplo, estratégias utilizando controle neuroelétrico e realimentação sensorial.

A seguir apresenta-se uma breve descrição destes métodos.

2.3.1 Sistema de Arreios

Como descrito anteriormente, as primeiras próteses eram geralmente dispositivos passivos que dependiam de membros sadios para seu posicionamento e controle. No final do século XIX as primeiras próteses *Body-Powered* foram desenvolvidas. Esse projeto de extremo sucesso permitiu o controle do dispositivo de tal maneira que movimentos de parte do corpo se refletissem em movimentos de segmentos da prótese. Apesar de algumas modificações, o projeto continua basicamente o mesmo e é o mecanismo de controle mais popular entre os usuários. As razões para tal sucesso não são bem estabelecidas, mas de acordo com Doeringer & Hogan (1995) [17] alguns dos principais fatores são:

- Ele resulta em uma prótese relativamente barata;
- A prótese final não é muito pesada;
- Após treinamento, o usuário passa a utilizar a prótese como uma extensão natural de seu corpo, tendo, por exemplo, a noção do peso e dimensão do membro protético.

Kruit & Cool (1989)[7] descrevem como principais problemas deste mecanismo, os seguintes fatores:

- O mecanismo de “arreios” utilizados para propagar os movimentos do corpo é geralmente desconfortável;
- A movimentação das próteses exige forças consideravelmente altas;
- O número de entradas de controle é limitado e dessa forma o número de graus de liberdade da prótese é também limitado.

2.3.2 Controle Mioelétrico

O controle mioelétrico utiliza a atividade elétrica de contração do músculo como sinal de controle para próteses. A idéia do controle mioelétrico não é nova e surgiu aproximadamente em 1948 (Scott & Parker, 1988) [32]. As próteses mioelétricas normalmente não

requerem cabos para controle e, em algumas situações, não existe a necessidade de cintas para a suspensão.

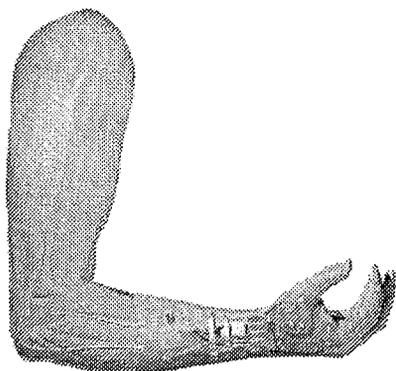


Figura 2.5: Prótese mioelétrica atual.

A Figura 2.5 ilustra uma prótese mioelétrica atual. Seu funcionamento pode ser descrito da seguinte forma: o cérebro “dá a ordem” para que a musculatura do braço se contraia através de impulsos que trafegam pelos nervos e atingem a placa motora de um dado músculo, que por sua vez provoca a contração muscular. A atividade muscular é então captada por eletrodos e utilizada para ativar o sistema atuador da

prótese. O soquete (adptador mecânico da prótese ao corpo) e os eletrodos para uma prótese mioelétrica estão mostrados na Figura 2.6.

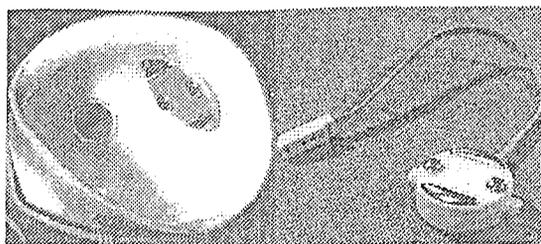


Figura 2.6: Soquete para um braço e eletrodos para uma prótese mioelétrica.

As primeiras próteses mioelétricas utilizavam um sistema de controle denominado “dois-sítios dois-estados”, onde um par de eletrodos é colocado sobre dois músculos. A contração de um desses músculos produz a abertura da mão até o músculo relaxar. O músculo antagonista é usado da mesma maneira para controlar o fechamento da mão. Como explicado por Scott & Parker (1988) [32], essa estratégia trabalha de modo análogo ao corpo humano - dois músculos antagonistas (ou conjunto de músculos) controlam o movimento de uma junta. Contudo, como os pacientes devem aprender a gerar contrações independentes dos músculos - o que requer um alto grau de concentração - o treinamento

pode ser longo, exigindo um grande esforço mental. Existem também algumas situações em que não é possível encontrar dois músculos “de controle” ou necessita-se controlar mais de uma junta. Para essas situações outras abordagens foram desenvolvidas. Como por exemplo os sistemas de controle “um-sítio três-estados” - uma pequena contração de músculos produz o fechamento da mão, uma grande contração causa sua abertura e na ausência de sinal a mão pára - e o sistema “um-sítio dois-estados” - a contração dos músculos abre a mão e quando não existe sinal a mão fecha.

Atualmente existe um grande número de métodos utilizando controle proporcional baseado no sinal eletromiográfico, para controlar a velocidade de atuação, o torque e a posição das juntas de uma prótese. Contudo, devido à natureza do sinal mioelétrico, erros e imprecisões ocorrerão por diversas razões (Hoff, 1991) [16].

Os sinais mioelétricos podem ser detectados usando-se basicamente dois tipos de eletrodos: eletrodos de superfície, localizados na superfície da pele, e eletrodos de agulha, inseridos em posições relevantes do músculo. Em ambos os casos os eletrodos produzirão uma diferença de potencial relativa à uma referência (geralmente um outro eletrodo localizado em outra parte do corpo). Esta tensão é resultado de uma ativação assíncrona de centenas de fibras musculares. O sinal assemelha-se a um ruído randômico, modulado em amplitude por uma entrada voluntária. Sua forma depende de variáveis tais como força e velocidade de ativação, posicionamento e tipos de eletrodos usados em sua detecção, circuitos eletrônicos utilizados na aquisição, amplificação e processamento (O'Neill *et al.*, 1994) [37].

2.3.3 Controle Neuroelétrico

Embora os músculos responsáveis por controlar uma função específica possam não estar presentes ou possam estar severamente danificados, os nervos periféricos que possuem o neurônio motor para aqueles músculos podem estar acessíveis na parte remanescente do membro (uma descrição completa sobre o sistema neural e a condução dos sinais através dos nervos pode ser encontrada em Guyton (1991) [14] e De Luca (1979) [27]). A possibilidade de coletar e processar os sinais diretamente dos nervos revela uma maneira

excitante de melhorar o controle de próteses.

De Luca (1978) [26] apresentou um possível esquema para empregar essa metodologia (Figura 2.7). Os sinais neuroelétricos podem ser coletados por eletrodos especiais implantados no corpo e anexados ao nervo relevante. O sinal modulado em frequência é transmitido a um receptor localizado no soquete da prótese para processamento. A energia para as unidades implantadas pode ser suprida via um receptor de potência implantado o qual é energizado por uma fonte externa de rádio-frequência.

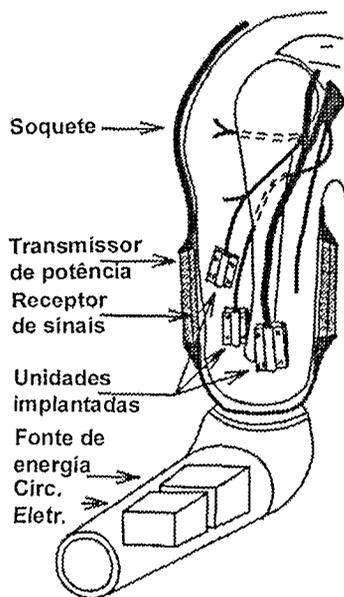


Figura 2.7: Prótese neuroelétrica.

Contudo, segundo De Luca, essa interessante idéia possui alguns problemas: é muito difícil projetar eletrodos especiais e anexá-los ao nervo de tal forma que eles não danifiquem ou induzam a degeneração do nervo e os sinais gravados podem tornar-se, a longo prazo, não confiáveis ou inconsistentes. Estas dificuldades são as principais razões pelas quais não existem muitas pesquisas sobre o assunto, mas, com o desenvolvimento de novas técnicas cirúrgicas, novos dispositivos eletrônicos e novos mecanismos protéticos, o controle neuroelétrico pode novamente ressurgir como opção para pacientes e profissionais da área.

2.3.4 Realimentação Sensorial

A Figura 2.8 mostra um diagrama de fluxo de sinais homem-prótese. Os sinais de realimentação do tipo A são visuais e auditivos e existem na maioria dos sistemas protéticos. A realimentação do tipo B é sensorial e pode ser estimulada através de vibrações mecânicas ou elétricas sobre a pele. A realimentação do tipo C é um controle necessário à planta do sistema.

Idealmente as próteses deveriam trabalhar em um *loop* fechado com o sistema neuromuscular remanescente. Isso poderia fornecer, além de informações sobre o objeto que a prótese toca, a ação que ela realmente estaria executando. Com isto, o usuário seria capaz

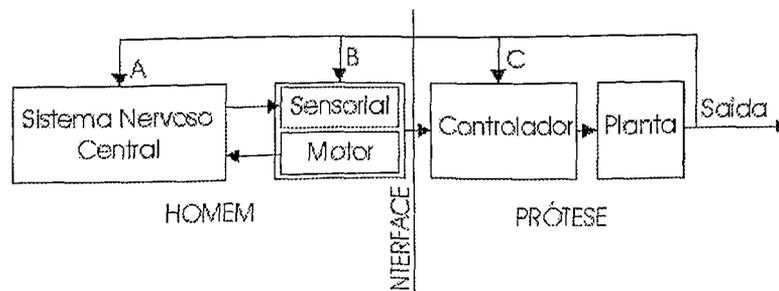


Figura 2.8: Diagrama de um sistema homem-prótese mostrando possíveis caminhos de informações.

de controlar determinadas ações ou mesmo corrigir um comando errado. A realimentação pode possibilitar também um controle interativo de vários parâmetros tais como posição, força, escorregamento e sobrecarga. As próteses atuais trabalham com informações de realimentação fornecidas pelo monitoramento visual do movimento das mesmas, ruído mecânico, variações de vibração e pressões exercidas pelo soquete sobre a pele.

Patterson e Katz (1992) [21] apresentaram uma revisão das atividades desenvolvidas em pesquisas nesse campo e analisaram sistemas de membros superiores de *loop* fechado para fornecer os melhores estímulos de mensagens de realimentação ao corpo. A hipótese inicial assumida por eles é que quando se segura um objeto não se espera ruído, vibração ou eletroestimulação, espera-se um estímulo natural de pressão. Para explorar essa hipótese, diferentes sistemas foram projetados e implementados de tal forma que cinco grupos de realimentação puderam ser avaliados: somente pressão, somente vibração, somente visão, pressão mais visão e vibração mais pressão. Os estímulos foram aplicados na região acima do antebraço. Os autores concluíram que os experimentos em que somente pressão e somente vibração foram aplicadas obtiveram os maiores erros na execução de algumas tarefas previamente estabelecidas. As condições envolvendo realimentação visual tiveram erros significativamente menores, enquanto que com pressão mais visão a taxa de erro foi mínima.

2.4 Conclusão

Este capítulo apresentou alguns tipos de próteses de membros artificiais existentes na atualidade, bem como uma revisão sobre o estado da arte de suas técnicas de controle. O capítulo seguinte apresenta métodos de processamento de sinais eletromiográficos capazes de extrair e classificar informações do sinal EMG.

Capítulo 3

Processamento de Sinais Eletromiográficos

3.1 Introdução

O processamento de sinais EMG consiste na manipulação do sinal resultante de uma atividade muscular, normalmente, através de um computador. Isto inclui análises visando a determinação das propriedades do sinal, estabelecendo assim, uma faixa em que estas podem ser consideradas normais dentro do contexto de um estudo em particular. Para tal, utiliza-se um conjunto de técnicas capazes de identificar, extrair e classificar suas características.

Para que o leitor possa compreender o sistema de aquisição e classificação de sinais EMG desenvolvido neste trabalho (descrito nos Capítulos 4 e 5), o presente capítulo tem como objetivo apresentar uma revisão sobre as várias técnicas de processamento de sinais, enfocando métodos que levam em conta características inerentes de sinais EMG. São abordados temas como análise no domínio do tempo, modelos autoregressivos e classificadores neurais.

3.2 Fisiologia da Contração Muscular

O sinal EMG observado na superfície da pele é a soma de milhares de potenciais elétricos (conhecidos como potenciais de ação) gerados nas fibras musculares, quando excitadas por neurônios motores. Fisiologicamente pode-se representar a seqüência funcional do processo de contração do músculo esquelético da seguinte maneira: a ativação de um neurônio motor produz um potencial de ação que se propaga ao longo de seu axônio até a placa motora; este propagará o potencial de ação que se estende por toda a fibra muscular. Isso ativa fibras contrácteis, com a conseqüente geração de força. Mais detalhes sobre este processo e uma revisão completa sobre o sistema neuromuscular, incluindo sua fisiologia e anatomia, podem ser encontrados em Cram (1998) [18].

3.3 O Sinal Eletromiográfico

O sinal eletromiográfico (Figura 3.1) é uma manifestação de uma ativação neuromuscular associada a uma contração muscular (De Luca, 1979) [27]. Este sinal é extremamente complexo, sendo afetado pelas propriedades anatômicas e fisiológicas dos músculos, pelo esquema de controle do sistema nervoso periférico, bem como pelas características dos instrumentos que são usados para detectá-lo e observá-lo.

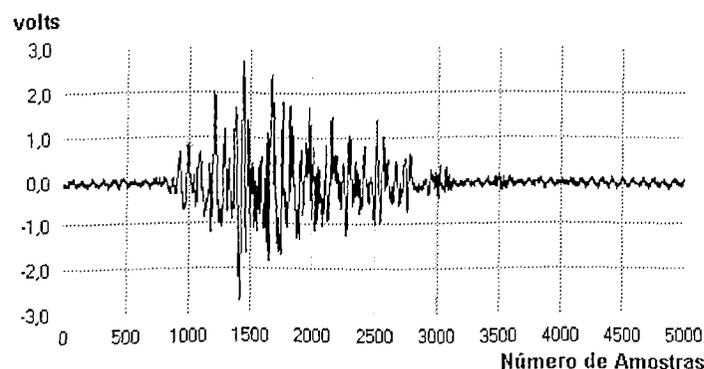


Figura 3.1: Sinal eletromiográfico proveniente de uma contração isométrica do tríceps (cabeça medial). O sinal foi amplificado 4400 vezes e adquirido a uma freqüência de 5 kHz.

A amplitude do potencial de ação depende do diâmetro da fibra muscular, da distância entre as fibras musculares ativas e do posicionamento e das propriedades dos eletrodos. No tecido muscular humano, a amplitude aumenta de acordo com a Equação 3.1.

$$V = ka^{1,7} \quad (3.1)$$

onde a é o raio da fibra muscular e k uma constante que relaciona a distância entre a fibra ativa e os eletrodos (De Luca, 1979) [27].

O sinal EMG possui natureza estocástica e pode ser representado, razoavelmente, por uma função de distribuição Gaussiana. Sua amplitude pode variar de 0 a 6 mV (pico-a-pico) ou 0 a 1,5 mV (rms). A maior parte da energia útil do sinal é limitada na faixa de frequência compreendida entre 0 a 500 Hz, com energia dominante entre 50 a 150 Hz (De Luca, 1996) [28].

As seções seguintes apresentam técnicas de processamento capazes de extrair e classificar informações de sinais EMG.

3.4 Análise no domínio do tempo

3.4.1 Introdução à terminologia

O termo **processo** ocorre freqüentemente na literatura e pode ser entendido de duas maneiras. Ele pode se referir a uma estrutura ou sistema, de origem biológica ou não, que gera as variáveis ou sinais de interesse. Ele pode, igualmente, se referir às propriedades inerentes dos sinais (Challis & Kitney, 1990)[23]. Como exemplo, a Equação 3.2 pode se referir a um processo contínuo senoidal de frequência angular ω , defasamento θ e amplitude x_0 .

$$x(t) = x_0 \text{sen}(\omega t + \theta) \quad (3.2)$$

A **estacionaridade** do sinal é outro fator fundamental para várias análises. Um processo fracamente estacionário pode ser definido como aquele que possui seus primeiro e segundo momentos estatísticos invariantes no tempo (Challis & Kitney, 1990)[23]. Isto significa que, se por exemplo, um processo que gera uma seqüência de dados $x(1), x(2), \dots, x(n)$ for considerado estacionário, então a média e o desvio padrão das amostras daquele conjunto de dados obtidas hoje, deverão ser iguais as obtidas a um ano atrás; e serão as mesmas no próximo ano.

Outro fator importante para se classificar um processo é definir se ele é ou não **determinístico**. Um processo determinístico é aquele em que uma análise linear sobre uma parte do sinal pode ser usada para prever ou determinar seu trajeto futuro (Challis & Kitney, 1990)[23]. Por exemplo, se uma análise mostrou que o segmento de um sinal é decomposto em duas senóides (Equação 3.3), pode-se facilmente determinar o trajeto futuro do sinal. Por outro lado, um processo puramente **não-determinístico** é aquele em que não se pode, apenas através da análise de um segmento do sinal, determinar seu trajeto futuro (Challis & Kitney, 1990)[23].

$$x(t) = x_0 \cos(\omega t + \theta) + \frac{x_0}{3} \cos(3\omega t + \theta) \quad (3.3)$$

A maioria dos processos de sinais reais encontrados na biologia e medicina é formado tanto por componentes determinísticas quanto por não-determinísticas e, freqüentemente, requer a análise separada de cada uma destas partes. O Teorema da Decomposição (Challis & Kitney, 1982)[22], que pode ser aplicado a processos estacionários discretos, garante que tais processos podem ser decompostos na soma de pares de processos - dos quais um é puramente determinístico e o outro puramente não-determinístico - que não são correlacionados um com o outro. A composição destes dois processos é conhecida como **processo estocástico**. Seu estado futuro pode ser parcialmente estimado através de seu estado presente, sendo desconhecidas as componentes que dependem de suas propriedades não-determinísticas. Essas componentes são usualmente regidas pelas distribuições de probabilidade, cujas propriedades podem ser utilizadas para fazer estimativas sobre o processo dentro de um certo limite de confiabilidade.

Finalmente, para completar a introdução à terminologia abordaremos o termo **randomicidade**. Uma série de dados é considerada randômica quando qualquer uma de suas amostras individuais podem ocorrer em qualquer ordem e em qualquer período de tempo (Papoulis, 1984)[31].

3.4.2 Medidas das propriedades do sinal

Existem várias medidas diferentes no domínio do tempo que podem caracterizar o sinal. Para um sinal discreto $x(n)$ com N amostras equidistantes essas medidas são definidas algebricamente como: média (Equação 3.4), variância (Equação 3.5), onde $\sqrt{s^2}$ é definida como desvio padrão, e valor RMS - *Root Mean Square* (Equação 3.6).

$$X_m = \frac{1}{N} \sum_{n=0}^{N-1} x(n) \quad (3.4)$$

$$s^2 = \frac{1}{N} \sum_{n=0}^{N-1} (x(n) - X_m)^2 \quad (3.5)$$

$$X_{RMS} = \sqrt{\frac{1}{N} \sum_{n=0}^{N-1} x(n)^2} \quad (3.6)$$

Observe que todas as estimativas são baseadas em somas de $x(n)$ e $x(n)^2$, e dessa forma não requerem um grande esforço computacional para cálculo.

3.4.3 Análise de Séries Temporais - Conceitos Gerais

Uma série temporal é uma seqüência cronológica de observações sobre uma variável em particular (Cryer, 1986) [8], como por exemplo, a amplitude do sinal EMG. A análise de séries temporais envolve um conjunto de técnicas para estudar dados que possuem uma característica posicional simples. Esta característica pode estar tanto no domínio do tempo ou do espaço. Para que a análise através de séries temporais seja válida é necessário que os dados estejam regularmente espaçados. As análises de séries temporais possuem basicamente dois objetivos: entender ou modelar o mecanismo estocástico que rege uma série observada e prever valores futuros de uma série com base na história da mesma.

Os procedimentos para a análise de séries temporais incluem:

- Correlação-cruzada: identifica e localiza posições de alta correlação entre duas seqüências;
- Auto-correlação: compara uma seqüência com ela mesma para determinar a correlação entre medidas sucessivas;
- Regressão: analisa a tendência de uma variável com base em seu estado passado.

Cada um destes procedimentos é descrito a seguir.

Correlação

Muitas vezes é necessário quantificar o grau de interdependência entre processos, ou estabelecer a similaridade entre um conjunto de dados com outros. Esta relação entre variáveis pode ser definida e quantificada matematicamente através da correlação.

A **correlação** entre duas seqüências de dados, cada qual constituída de valores amostrados simultaneamente, pode ser obtida através da soma dos produtos de pares de pontos correspondentes. Se as seqüências forem variáveis independentes e aleatórias, a soma dos produtos tenderá a um valor pequeno, próximo ao zero, e randômico. Isto ocorre porque os produtos dos pares de pontos tendem a se cancelarem no somatório, visto que todos os números, positivos e negativos, possuem a mesma chance de ocorrer.

A **correlação-cruzada** r_{12} entre duas seqüências de dados, $x_1(n)$ e $x_2(n)$, cada qual contendo N amostras, pode ser definida pela Equação 3.7.

$$r_{12} = \sum_{n=0}^{N-1} x_1(n)x_2(n) \quad (3.7)$$

Esta definição de correlação-cruzada fornece um resultado que depende do número de pontos amostrados. Esta dependência pode ser eliminada pela normalização do resultado, ou seja, pela divisão do valor do somatório por N . Dessa forma a equação 3.7 torna-se:

$$r_{12} = \frac{1}{N} \sum_{n=0}^{N-1} x_1(n)x_2(n) \quad (3.8)$$

Contudo, esta definição necessita modificações para ser útil, pois em alguns casos, como por exemplo aqueles em que as formas de ondas estão apenas defasadas uma em relação a outra (Figura 3.2a), ela pode indicar correlação zero, embora as formas de onda sejam 100% correlacionadas. Este problema pode ser solucionado através do deslocamento ou atraso de uma das formas de onda em relação à outra. Tipicamente $x_2(n)$ é deslocada para a esquerda, o que equivale isto a trocar $x_2(n)$ por $x_2(n + j)$, onde j representa o atraso que é definido pelo número de pontos que x_2 foi deslocada para a esquerda. Tal situação é representada na Figura 3.2b.

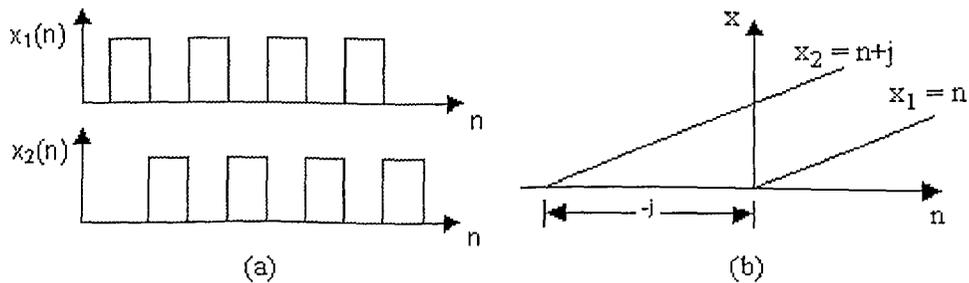


Figura 3.2: (a) Formas de onda defasadas. (b) Forma de onda x_2 deslocada de j atrasos à esquerda de x_1 .

Uma alternativa equivalente é deslocar x_1 para a direita. Desta maneira a Equação 3.8, que define a correlação-cruzada, torna-se:

$$r_{12}(j) = \frac{1}{N} \sum_{n=0}^{N-1} x_1(n)x_2(n+j) = r_{21}(-j) = \frac{1}{N} \sum_{n=0}^{N-1} x_2(n)x_1(n-j) \quad (3.9)$$

Outro problema pode ser observado na Figura 3.3, em que as formas de onda $x_1(n)$ e $x_3(n)$ são as mesmas, diferindo apenas em amplitude. Note que a correlação entre $x_1(n)$ e $x_2(n)$ é a mesma que $x_3(n)$ e $x_4(n)$. Contudo, as correlações-cruzadas $r_{12}(j)$ e $r_{34}(j)$ são diferentes, se calculadas em valores absolutos de dados.

Tal situação pode ser retificada normalizando-se as correlações-cruzadas $r_{12}(j)$ e $r_{34}(j)$ pelo fator ξ indicado pela Equação 3.10 (Ifeachor, 1993) [20].

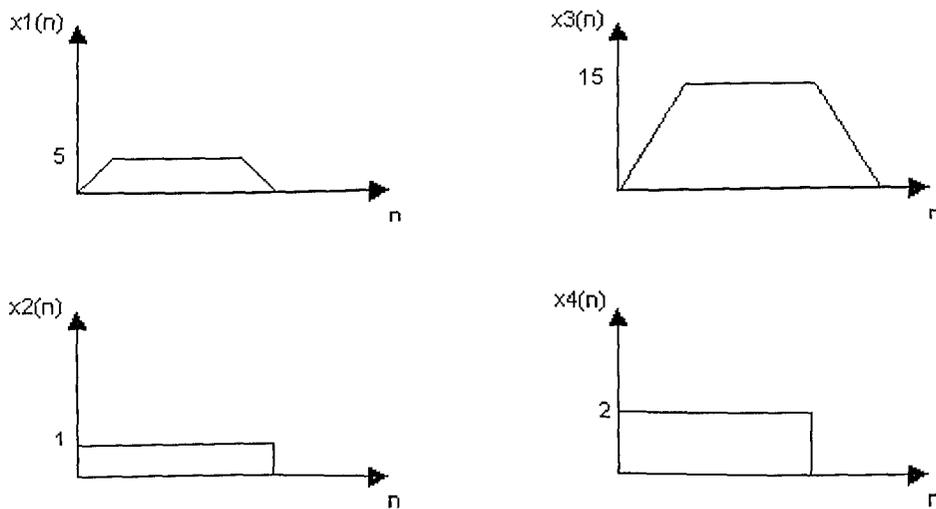


Figura 3.3: Pares de formas de ondas $\{x_1(n), x_2(n)\}$, $\{x_3(n), x_4(n)\}$, de diferentes amplitudes.

$$\xi = \frac{1}{N} \left[\sum_{n=0}^{N-1} x_1^2(n) \sum_{n=0}^{N-1} x_2^2(n) \right]^{\frac{1}{2}} \quad (3.10)$$

Assim as expressões normalizadas para $r_{12}(j)$ e $r_{34}(j)$ podem ser dadas por:

$$\rho_{12}(j) = \frac{r_{12}(j)}{\xi} \quad (3.11)$$

$$\rho_{34}(j) = \frac{r_{34}(j)}{\xi} \quad (3.12)$$

O termo $\rho_{xy}(j)$ é conhecido como coeficiente de correlação-cruzada e seu valor situa-se entre -1 e $+1$. O valor $+1$ indica 100% de correlação na mesma fase e o valor -1 indica 100% de correlação em fases opostas. O valor zero indica que os sinais são completamente independentes. Este seria o caso, por exemplo, se uma das formas de onda fosse completamente randômica.

Auto-Correlação

Existirão situações em que necessitaremos analisar a correlação de uma onda com ela mesma. Nestes casos utilizaremos o processo conhecido como **auto-correlação**. A auto-correlação de uma forma de onda é definida por:

$$r_{11}(j) = \frac{1}{N} \sum_{n=0}^{N-1} x_1(n)x_1(n+j) \quad (3.13)$$

A função auto-correlação possui a seguinte propriedade:

$$r_{11}(0) = \frac{1}{N} \sum_{n=0}^{N-1} x_1(n)^2 = S \quad (3.14)$$

onde S é a energia normalizada da forma de onda. Isto fornece um método para o cálculo da energia do sinal. Se a forma de onda for completamente randômica, por exemplo um ruído branco ou gaussiano, a auto-correlação terá seu valor de pico em $j = 0$ e se reduzirá a uma flutuação randômica de pequenas amplitudes para valores de j maiores que 1 (Figura 3.4). Portanto, podemos verificar a randomicidade de um sinal através de sua auto-correlação.

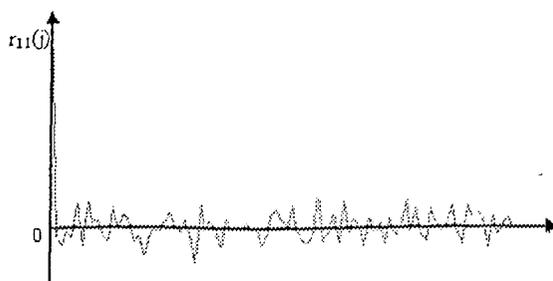


Figura 3.4: Função auto-correlação de uma forma de onda randômica.

Regressão

A maioria dos dados resultantes de um experimento consiste de uma seqüência de valores de dados ou amostras individuais, cada uma delas podendo ser distribuída de

alguma maneira e caracterizada por um valor médio, uma variância e outros parâmetros necessários para definir sua distribuição.

O objetivo do processo de **regressão** é determinar os parâmetros de uma reta que formam uma boa aproximação para picos de distribuições sucessivas. Por exemplo, em processos nos quais não existem dados suficientes para definir uma distribuição em cada ponto de tempo, ela pode ser utilizada como um método estimativo, em que o objetivo é obter o melhor ponto a ser ajustado no conjunto de dados.

Até o momento apresentou-se uma breve introdução sobre um grupo de técnicas em que as propriedades dos sinais, ou relações entre eles, podem ser estudadas diretamente no domínio do tempo. Os métodos descritos são gerais e aplicáveis a qualquer sinal unidimensional.

Pode-se concluir que antes de se inicializar qualquer tipo de análise sobre um sinal, é sempre útil obter algumas informações básicas sobre o mesmo. Isto pode ser feito através de questionamentos tais como: Existe uma tendência? O sinal é randômico? Ele é estacionário? Qual é sua média e desvio padrão? Ele é periódico?

Tendo em mãos as medidas básicas do sinal no domínio do tempo, pode-se agora, através de um método adequado, extrair as características do mesmo.

3.5 Extração de Características - O Modelo Autoregressivo

Na prática, o espectro dos sinais é sempre degradado por ruídos externos. Quando a razão sinal/ruído é baixa, métodos tradicionais de análise não podem fornecer um espectro de potência preciso. A falha destes métodos, como por exemplo a Transformada de Fourier, pode ser atribuída às seguintes limitações (Akay, 1994) [1]: a Transformada de Fourier não fornece uma boa resolução em frequência e dessa forma pode não permitir discriminar dois ou mais sinais com baixa razão sinal/ruído; o processo de janelamento do sinal durante sua análise provoca perdas de informações, causando assim, uma fuga

espectral.

As limitações da Transformada de Fourier podem ser solucionadas através do uso de métodos de análise paramétrica (ou métodos de análise de séries temporais). O modelamento paramétrico de sinais envolve a escolha de um modelo apropriado para os mesmos e para a estimativa dos parâmetros do modelo. Estes parâmetros podem ser usados para calcular o espectro de potência do sinal, para classificá-lo, ou para realizar compressões de dados e reconhecimento de padrões.

A análise de séries temporais é baseada no modelamento do sinal como uma combinação linear de seus valores passados. Existem várias classes de modelos de séries temporais. Um modelo que depende somente das saídas anteriores do sistema é denominado autoregressivo (*autoregressive model* - AR), enquanto um modelo que depende somente das entradas do sistema é denominado modelo de média-móvel (*moving-average model* - MA); e um modelo baseado tanto na entrada como na saída do sistema é chamado de modelo autoregressivo de média-móvel (*autoregressive-moving-average model* - ARMA).

O modelo AR é o mais popular dentre os métodos paramétricos para a estimativa do espectro de potência. Estimativas precisas da função densidade espectral de potência (*Power Spectral Density Function* - PSD) podem ser obtidas através da resolução de um conjunto de equações lineares. Este modelo vem sendo utilizado com êxito em diversas pesquisas que envolvem o processamento de sinais biomédicos.

O modelo AR de uma série $y(n)$ é definido por:

$$\hat{y}(n) = \sum_{m=1}^M a_m(n)y(n-m) + e(n) \quad (3.15)$$

onde $\hat{y}(n)$ representa o valor estimado da série $y(n)$ no tempo discreto n , a_m são os parâmetros ou coeficientes do modelo AR, $e(n)$ é o erro de estimação, e M é a ordem do modelo.

Desta forma, o modelo AR assume que o atual valor presente da série temporal $y(n)$ é dependente dos valores anteriores $y(n-1)$, $y(n-2)$, etc. O grau de dependência é definido no modelo através de sua ordem.

Os parâmetros do modelo AR contêm informações sobre as características do sinal. Considere como exemplo um padrão EMG. Ao calcularmos os coeficientes do modelo AR para o sinal, podemos obter informações sobre o modo de contração muscular. Para diferentes modos de contração muscular, diferentes conjuntos de parâmetros são identificados. Tais parâmetros formam um conjunto de características para o reconhecimento e classificação de padrões.

3.5.1 Cálculo dos Parâmetros do Modelo Autoregressivo

Existem vários métodos para calcular os parâmetros do modelo AR. A escolha de um destes métodos deve levar em consideração tanto o grau de dificuldade na determinação dos parâmetros e a velocidade de processamento exigida na aplicação, bem como a estacionaridade do sinal.

Dentre os principais métodos para o cálculo dos parâmetros do modelo AR pode-se citar: o método da autocorrelação (ou método de Yule-Walker), o método da covariância, o método da decomposição de Cholesky, o método de Burg, e os métodos AR adaptativos utilizando os algoritmos de mínimos quadrados (LMS - *Least Mean Square*) e de mínimos quadrados recursivos (RLS - (*Recursive Least Square*)). Além destas técnicas tradicionais, métodos alternativos, como por exemplo, redes neurais artificiais (Gunawardana, 1995) [12], vêm sendo utilizados na determinação dos parâmetros.

Com exceção dos métodos AR adaptativos, os métodos tradicionais citados acima possuem um fator limitante: eles requerem a estacionaridade do sinal para que o cálculo dos parâmetros do modelo possa ser determinado apropriadamente (Akay, 1994) [1]. Isto ocorre pois tais métodos não detectam mudanças lentas no espectro de sinais não-estacionários ou fracamente estacionários, como é o caso, por exemplo, do sinal EMG. Tal limitação pode ser contornada estimando-se adaptativamente os parâmetros do modelo AR para cada amostra (Akay, 1994) [1]. Os próximos parágrafos descrevem os passos para a determinação dos parâmetros do modelo AR utilizando o algoritmo adaptativo, bastante usado no processamento de sinais biomédicos, principalmente na extração de características do sinal EMG.

O método AR utilizando o algoritmo adaptativo, também conhecido como preditor linear adaptativo, é apresentado no diagrama de blocos da Figura 3.5. Observe que ele fornece um canal de referência $y(n-1)$ pelo atraso do canal do sinal principal $y(n)$ de uma amostra. O papel do estimador ou filtro adaptativo é estimar a amostra de entrada atual com base em amostras de entradas anteriores pela minimização do erro de estimação para cada amostra.

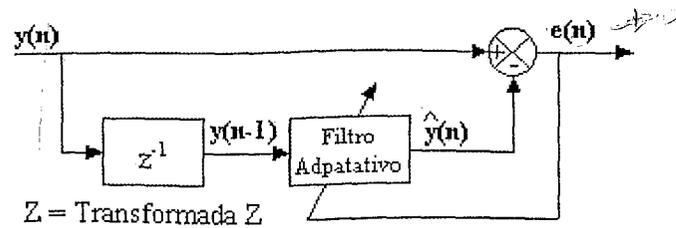


Figura 3.5: Estimador linear adaptativo.

O preditor linear adaptativo, baseado no algoritmo LMS, pode ser implementado conforme algoritmo a seguir (Akay, 1994) [1]:

- 1 - Inicialize todos os coeficientes do filtro $a_m(n)$ com zero.
- 2 - Repita os passos de 3 a 5 para todas as N amostras de $y(n)$, $n = 0, \dots, N - 1$.
- 3 - Calcule o valor estimado do sinal $y(n)$:

$$\hat{y}(n) = - \sum_{m=1}^M a_m(n) y(n-m) \quad (3.16)$$

- 4 - Calcule o erro de estimação $e(n)$:

$$e(n) = y(n) - \hat{y}(n) \quad (3.17)$$

- 5 - Atualize os coeficientes do modelo AR:

$$a_m(n+1) = a_m(n) - 2\mu e(n) y(n-m) \quad (3.18)$$

onde μ , $0 < \mu < 1$, é a constante de convergência do filtro.

Uma das características mais importantes para a análise de um sinal é sua função densidade espectral de potência (PSD). Uma vez que os coeficientes do filtro adaptativo convergiram para valores finais, podemos calcular a função PSD de um processo AR pela equação:

$$S_{AR}(\omega) = \frac{\sigma_e^2}{\left| 1 + \sum_{m=1}^M a_m e^{-j\omega m \Delta t} \right|^2} \quad (3.19)$$

onde, σ_e^2 é a potência de $e(n)$, ω é a frequência, e Δt o intervalo de amostragem. Caso $e(n)$ assemelhe a um ruído branco, σ_e^2 será constante, e os únicos valores necessários para o cálculo da função PSD serão os coeficientes de predição a_m .

3.5.2 Determinação da Ordem do Modelo Autoregressivo

Uma vez que o modelo foi identificado e seus parâmetros estimados, deve-se analisar se o mesmo é adequado para representar o sinal. Tal análise deve ser aplicada aos resíduos (erro) do modelo (Hefftner *et al.*, 1988) [19].

Sendo $e(n)$ o erro entre o valor do sinal $y(n)$ e o valor $\hat{y}(n)$ estimado, o modelo somente será adequado quando $e(n)$ se assemelhar a um ruído randômico (por exemplo, ruído branco). Assim, a ordem do modelo deve ser escolhida para garantir que $e(n)$ seja próximo a um ruído branco (Hefftner *et al.*, 1988) [19].

Um primeiro passo de checagem do processo é a inspeção visual do gráfico dos resíduos. Este gráfico deve ilustrar claramente a natureza randômica dos resíduos de um modelo em particular.

Uma suposição importante para a análise descrita anteriormente é que a série temporal, que está sendo modelada, seja estacionária. Uma forma simples de se calcular a estacionaridade de um conjunto de dados randômicos amostrados (tal como o sinal EMG), é considerar a física do fenômeno que deu origem aos dados.

Considerando-se, por exemplo, a fisiologia de um sistema que produz um sinal mioelétrico e especialmente fatores tais como entrada neural, sangue ou suprimento de oxigênio para os músculos, mesmo quando não existem alterações voluntárias no estado do músculo, é improvável que sinais mioelétricos de longa duração sejam estacionários.

A atividade miolétrica deve, desta forma, ser analisada em curtos períodos de tempo durante os quais as entradas do sistema serão relativamente constantes e o sinal EMG será, possivelmente, fracamente estacionário.

Observa-se assim, que devido a natureza do sistema, a escolha da ordem do modelo AR para a discriminação das características dos sinais biomédicos, em geral não é uma tarefa simples, pois tais sinais não são séries simples, mas sim sinais divididos em várias séries temporais. Levando-se em conta a restrição de tempo computacional e, portanto, a ordem do modelo, é impossível definir uma ordem que satisfaça cada uma daquelas séries. A ordem de modelo deve, portanto, ser escolhida de maneira a produzir um sistema, razoavelmente, bem representado.

Uma vez encerrada a etapa de extração de características, podemos agora classicá-las.

3.6 Classificação de Padrões

Um dicionário de Português define um “padrão” como sendo um modelo ou exemplo - alguma coisa que pode ser copiada. Um padrão é também uma imitação de um modelo (Pal & Majumder, 1986) [30]. Contudo, ao descrever tipos de objetos nos mundos físicos e abstratos, a definição que vem à nossa mente é que um padrão é qualquer inter-relação distinguível de dados (analógicos ou digitais), eventos e/ou conceitos.

O reconhecimento de padrões tem como fundamento a simulação das capacidades cognitivas do ser-humano. Ele é a transformação de um nível sub-simbólico (sinais) para um nível simbólico (significados). Pode ser observado ainda que antes de tudo ele é também um processo de redução de informações (Rauber, 1997) [34]. Exemplos de aplicações em reconhecimento de padrões estão presentes em diversas áreas, por exemplo: reconhecimento automático da fala, classificação de sinais ECG, EEG e EMG, reconhecimento de manuscritos, etc.

Embora o reconhecimento de padrões seja aplicado em diferentes áreas, existem partes essenciais do processo de reconhecimento que são idênticas para todas. O diagrama de

blocos da Figura 3.6 mostra um modelo básico para classificação automática de padrões (Rauber, 1997) [34].

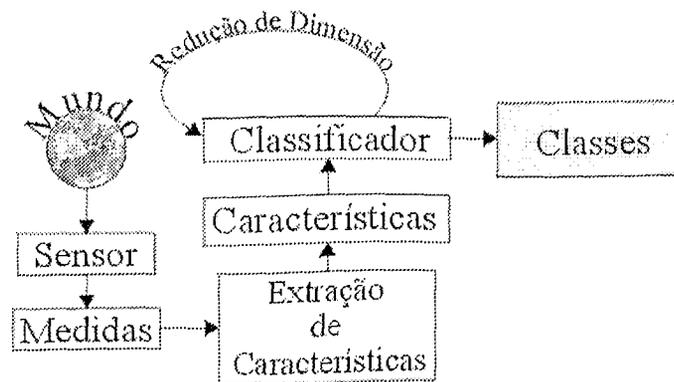


Figura 3.6: Modelo para classificação de padrões.

Na Figura 3.6 um sensor é associado a um processo gerador de sinais que coleta dados fisicamente mensuráveis. Um extrator de características converte os sinais puros em características processáveis pela máquina. As várias características compõem um vetor multidimensional. Geralmente, a dimensão desse vetor de características é muito grande ou às vezes irrelevante e redundante. Sendo assim, um processo de redução de dimensão é realizado. Isso significa que nem todas as características do conjunto original poderão ser utilizadas. O objetivo da redução do número de características é tornar o classificador mais eficiente em termos de armazenamento de dados e tempo de processamento. O novo conjunto será então processado por um classificador que categoriza os objetos do mundo real em classes.

Existem diversas técnicas para classificação de padrões, que vão desde arquiteturas probabilísticas à arquiteturas neurais (Rauber, 1997) [34]. Dentre estas diversas técnicas, optou-se pelo uso de classificadores neurais neste trabalho (as razões para tal serão esclarecidas no Capítulo 4). Os parágrafos que se seguem descrevem o mecanismo de funcionamento dos classificadores neurais e também o princípio básico por trás dos mesmos.

As redes neurais artificiais procuram imitar a arquitetura do cérebro de forma a se beneficiar de seus aspectos naturais (tal como seu poder de aprendizagem). É importante salientar que estamos diante de um simples modelo com inspiração no cérebro huma-

no, que é mais complexo e, além de tudo, pouco conhecido. Algumas propriedades dos neurônios biológicos consideradas essenciais para o entendimento dos temas a serem tratados adiante, serão apresentadas a seguir.

O Neurônio Biológico

Como qualquer célula biológica, o neurônio é delimitado por uma fina membrana celular, que além de sua função biológica normal possui determinadas propriedades essenciais para o funcionamento elétrico da mesma.

O neurônio biológico (Figura 3.7) pode ser entendido como sendo basicamente o dispositivo computacional elementar do sistema nervoso, possuindo várias entradas e uma saída. As entradas provêm das conexões sinápticas, que conectam a árvore dendrital aos axônios de outras células nervosas. Os sinais que chegam por estes axônios são impulsos eletroquímicos, e constituem a informação que o neurônio processará de alguma forma, para produzir um impulso nervoso em seu axônio. Uma conexão sináptica pode ser excitatória (quando provocar alterações no potencial da membrana, contribuindo para a formação de um impulso nervoso - potencial de ação - no axônio de saída) ou pode ser uma conexão inibitória (agindo de modo oposto).

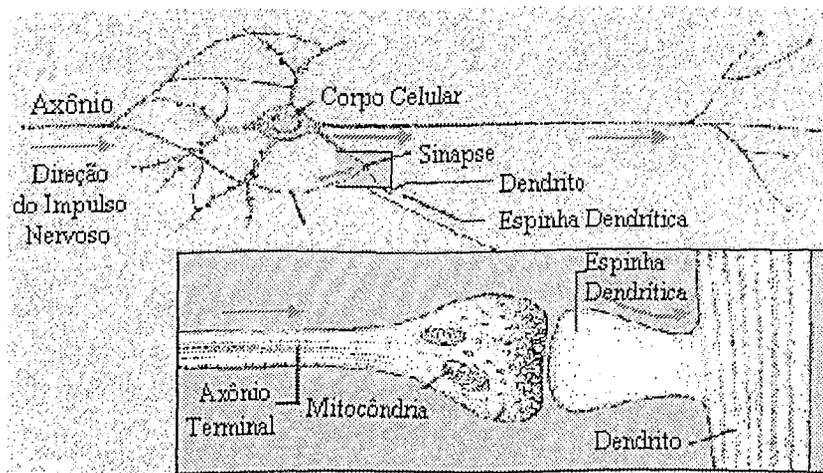


Figura 3.7: Representação do neurônio biológico e da seqüência de transmissão de impulsos.

A formação de um potencial de ação no axônio ou, mais especificamente, na sua membrana (Figura 3.8), ocorre quando a membrana sofre uma despolarização suficientemente acentuada para ultrapassar um determinado valor conhecido como limiar de disparo, ou limiar de ação. Quando isto ocorre o potencial de ação se propaga ao longo da fibra nervosa numa velocidade que pode variar de algumas dezenas de centímetros por segundo à 150 metros por segundo. Imediatamente após a geração de um potencial de ação (durante o período T_n), a membrana entra no período de refração absoluta (T_a), durante o qual é incapaz de produzir um outro potencial de ação. Após T_a , há o período de refração relativa (T_r) caracterizado por uma elevação no limiar de disparo que assintoticamente retornará ao seu valor normal.

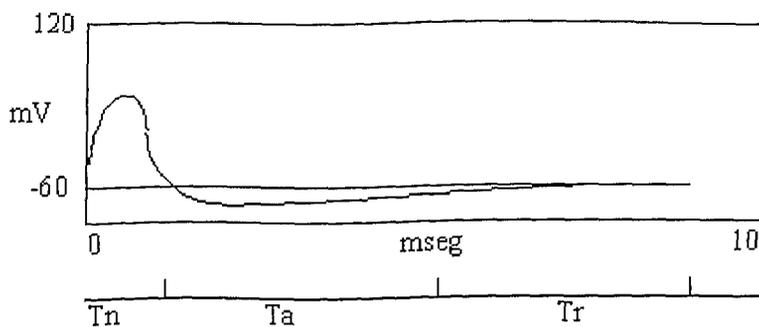


Figura 3.8: Intervalos de tempo característicos em decorrência do potencial de ação no axônio. T_n é o período da geração do potencial de ação, T_a é o período de refração absoluta e T_r é o período de refração relativa.

Um Modelo de Neurônio Artificial

A Figura 3.9 mostra um modelo de neurônio proposto por Fausett (1994) [10] com comportamento similar ao descrito. O modelo considera uma somatória de todos os sinais de entrada multiplicados pelos respectivos pesos (w), e uma função de ativação $f(x)$. A função de ativação pode assumir diversas formas matemáticas, mas basicamente representa como o resultado da somatória irá contribuir, ou não, para a propagação de

um potencial de saída.

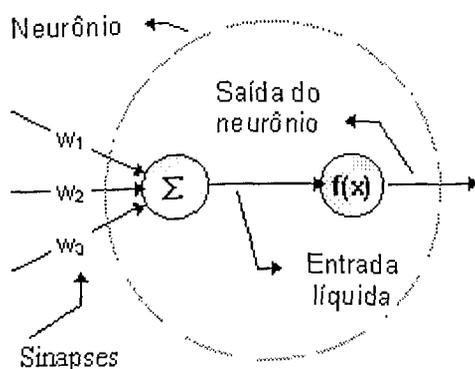


Figura 3.9: Modelo de neurônio.

Aquele neurônio pode agora fazer parte de uma rede neural tal como a mostrada na Figura 3.10.

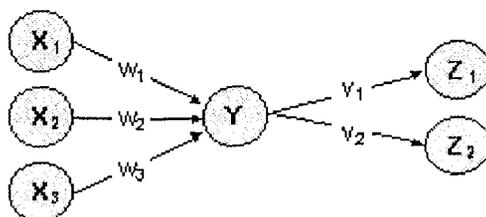


Figura 3.10: Uma rede neural simples.

Um Modelo de Rede Neural Artificial

Uma rede neural é caracterizada por seus padrões de conexão entre os neurônios (arquitetura), pelo método de determinação dos pesos entre as conexões (treinamento ou algoritmo de aprendizagem) e finalmente por sua função de ativação (Fausett, 1994) [10]. A afirmação de que uma rede neural pode “aprender” refere-se à possibilidade de alterar os pesos das conexões, fazendo com que hajam variações no padrão de saída; ou seja, treinar uma rede neural artificial é, basicamente, ajustar os valores numéricos das conexões

entre seus neurônios.

Atualmente existem inúmeras arquiteturas de redes neurais artificiais. Referências sobre elas podem ser encontradas em Braga *et al.* (1998) [29], Fausett (1994) [10], Gudwin (1996) [11], Haykin (1994) [15], Lippman (1987) [25], Prosdocimo (1996) [33], Rauber (1997) [34] e Welstead (1994) [42]. Dentre as arquiteturas neurais, uma das que tem obtido melhores resultados é a chamada MLP (*Multi-Layer Perceptron*), utilizando como mecanismo de treinamento o algoritmo conhecido como *Backpropagation*.

O *Backpropagation* ou regra delta generalizada é basicamente um método de gradiente descendente para minimização do erro quadrático total da saída calculada por uma rede. Seu objetivo é treinar a rede para alcançar um equilíbrio entre a habilidade de responder corretamente a padrões de entrada que foram utilizados no treinamento (memorização) e a habilidade de fornecer respostas razoáveis a padrões de entradas similares, mas não idênticos, à aqueles utilizados durante o treinamento (generalização).

Contudo, este treinamento pode apresentar alguns problemas devido à grande quantidade de variáveis envolvidas. Por exemplo, existe uma grande possibilidade de que este processo não chegue a convergir para o estado desejado, ou seja, poderá existir um erro entre a saída obtida pela rede e a saída desejada. E ainda, mesmo que haja convergência, isto pode ocorrer muito lentamente, exigindo assim um longo tempo de treinamento. Para tornar o processo mais rápido e mais estável, foram desenvolvidas uma série de modificações ao longo das últimas décadas (Fausett, 1994) [10], tais como:

- **Inicialização dos pesos pelo método Nguyen-Widrow:** realiza a inicialização dos pesos considerando a arquitetura da rede. Isto pode evitar que a rede não entre em saturação, aprendendo mais rapidamente no início do treinamento.
- **Momentum:** esta constante pode ser utilizada para aumentar a velocidade de treinamento. Sua influência na velocidade de aprendizagem baseia-se na consideração de que se o ajuste dos pesos está acontecendo sempre em uma direção específica, então, tais ajustes devem ser acelerados naquela direção. Às vezes o uso desta constante pode tornar o processo de convergência menos, ou totalmente, instável.

- **Treinamento dos padrões em ordens aleatórias:** isto pode tornar o treinamento estocástico, reduzindo a possibilidade de instabilidade no processo de treinamento.
- **Controle da taxa de aprendizagem e da constante de momentum através de Lógica Fuzzy:** o emprego de um controlador *fuzzy* permite um constante monitoramento no estado do sistema durante o treinamento. Se em um dado momento algum parâmetro necessitar ser modificado, a ação é automaticamente executada, com isto a velocidade de convergência é consideravelmente aumentada.

Um exemplo de arquitetura da rede neural MLP é mostrado na Figura 3.11. Note que, neste caso, a rede possui uma camada de neurônios de entrada, uma interna (oculta ou escondida) e uma de saída. Cada conexão mostrada possui, implicitamente, um peso associado. O valor associado à saída de cada neurônio dependerá de uma função de ativação que definirá como as entradas contribuirão para o resultado final.

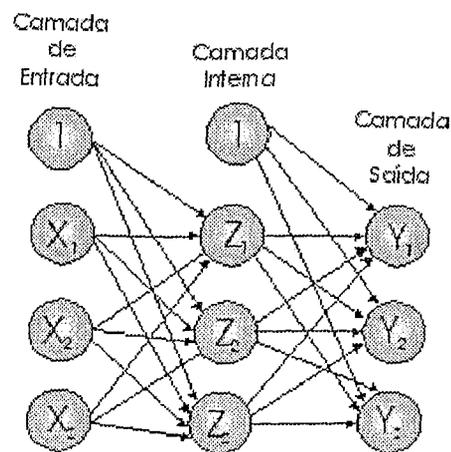


Figura 3.11: Arquitetura de uma rede neural MLP com uma camada escondida.

A função de ativação para a rede MLP com algoritmo *Backpropagation* precisa ser necessariamente diferenciável. Para que o processo de cálculos seja eficiente e rápido é desejável também que sua derivada seja facilmente calculada. Uma das funções de ativação

mais comuns é a sigmóide bipolar (Figura 3.12a) com imagem na faixa entre -1 e 1 ou a sigmóide binária (Figura 3.12b) com imagem na faixa entre 0 e 1.

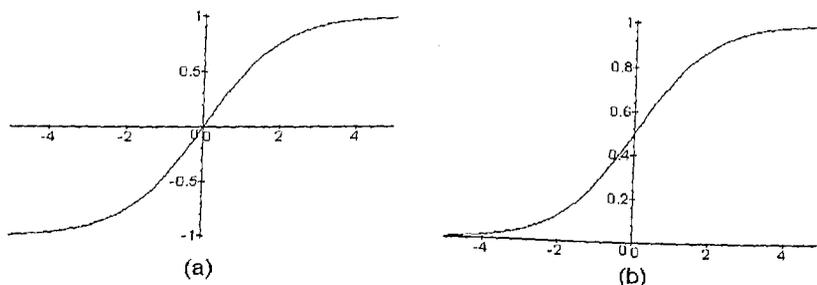


Figura 3.12: (a) Função sigmóide bipolar: $f(x) = \frac{2}{1+e^{-x}} - 1$. (b) Função sigmóide binária: $f(x) = \frac{1}{1+e^{-x}}$.

O processo de treinamento *Backpropagation* pode ser dividido em duas partes básicas:

- Propagação direta (*Feedforward*): os sinais fluem da entrada para a saída.
- Retropropagação (*Backforward*): uma vez que os sinais injetados na entrada alcançam a saída, pode-se calcular o erro entre a resposta obtida e a desejada, para todos os neurônios. E assim pode-se determinar o quanto cada neurônio contribui para uma saída correta.

Tendo a rede neural sido treinada, ela pode ser utilizada como elemento classificador. Neste trabalho uma rede neural realiza a classificação de padrões EMG, associando-os à classes de movimentos do braço. Os Capítulos 4 e 5 descrevem todas as etapas envolvidas neste processo de classificação.

3.7 Conclusão

Este capítulo apresentou uma revisão sobre os principais métodos de processamento utilizados na análise de sinais eletromiográficos. Observou-se que, com base na análise do comportamento do sinal, pode-se escolher métodos adequados para o seu processamento, evitando assim possíveis avaliações errôneas sobre o mesmo.

Capítulo 4

Descrição do Sistema Desenvolvido

4.1 Introdução

Conforme mencionado no Capítulo 1, um dos grandes desafios atuais no controle de membros protéticos é que o usuário controle a prótese de maneira mais natural possível. Neste sentido, diversas pesquisas têm utilizado a atividade eletromiográfica como sinal de controle para próteses. Porém, o que se nota é uma grande dificuldade no processamento daqueles sinais. Sendo assim, o presente trabalho propõe um possível sistema capaz de processar sinais EMG, extraíndo suas características e utilizando-as para o controle de próteses.

O sistema proposto e desenvolvido é mostrado esquematicamente na Figura 4.1. Ele pode ser considerado como uma extensão e junção de partes dos trabalhos de Hefftner *et al.* (1988) [19] e Gunawardana (1995) [13]. A transferência de informações entre cada uma de seus estágios é feita via arquivos de dados e o processamento de sinais realizado não é em tempo real.

O modelo apresentado na Figura 4.1 sugere seis estágios compondo o sistema de processamento e classificação de sinais EMG. São eles: Detecção, Condicionamento, Aquisição, Janelamento, Extração das Características e Classificação.

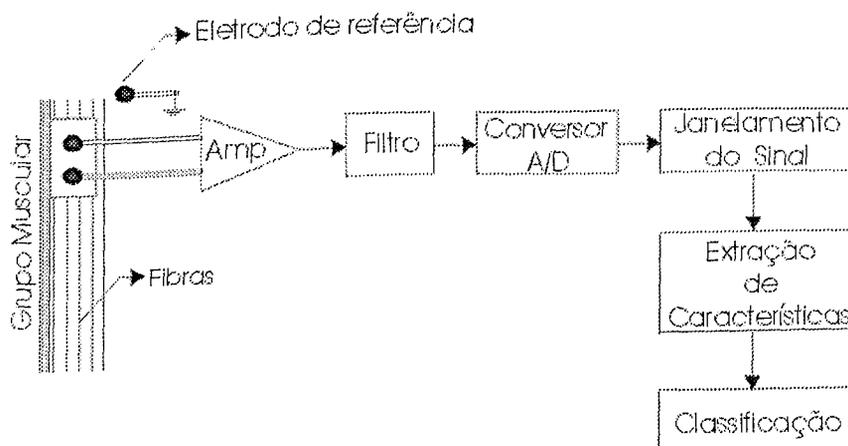


Figura 4.1: Sistema de processamento e classificação de sinais EMG.

4.2 Características Desejáveis para os Estágios

4.2.1 Estágio de Detecção

A detecção de sinais EMG é feita através de eletrodos. A escolha do eletrodo depende do tipo de músculo em estudo, sendo que para músculos grandes e superficiais, eletrodos de superfície podem ser empregados e para músculos pequenos e superficiais, ou para aqueles situados entre ou abaixo de outros músculos, podem ser usados eletrodos intramusculares (Türker, 1993) [41].

Os eletrodos de superfície podem ser ativos ou passivos (Cram *et al.* [18]). Os eletrodos ativos possuem alta impedância de entrada (1012 ohms) - sendo dessa forma insensíveis à mudanças na resistência elétrica da interface eletrodo-pele - e pré-amplificadores que minimizam ruídos e alterações no sinal EMG que podem ser provocadas pelo movimento de cabos. A Figura 4.2a mostra o diagrama de um circuito diferencial duplo utilizado na pré-amplificação: SD1 é o sinal diferencial do par de eletrodos superior, SD2 é o sinal diferencial do par de eletrodos inferior e DD é o sinal diferencial resultante de SD1 e SD2. Os sinais EMG detectados por eletrodos ativos (área sombreada da Figura 4.2b) indicam que estes reduzem consideravelmente o fenômeno de *cross-talk* entre sinais. Os eletrodos passivos caracterizam-se basicamente por possuírem baixas impedâncias de entrada e por

não possuem o estágio pré-amplificador, exigindo que a superfície de contato (pele) esteja bem limpa e que se utilize um gel para a diminuição da resistência da interface eletrodo-pele.

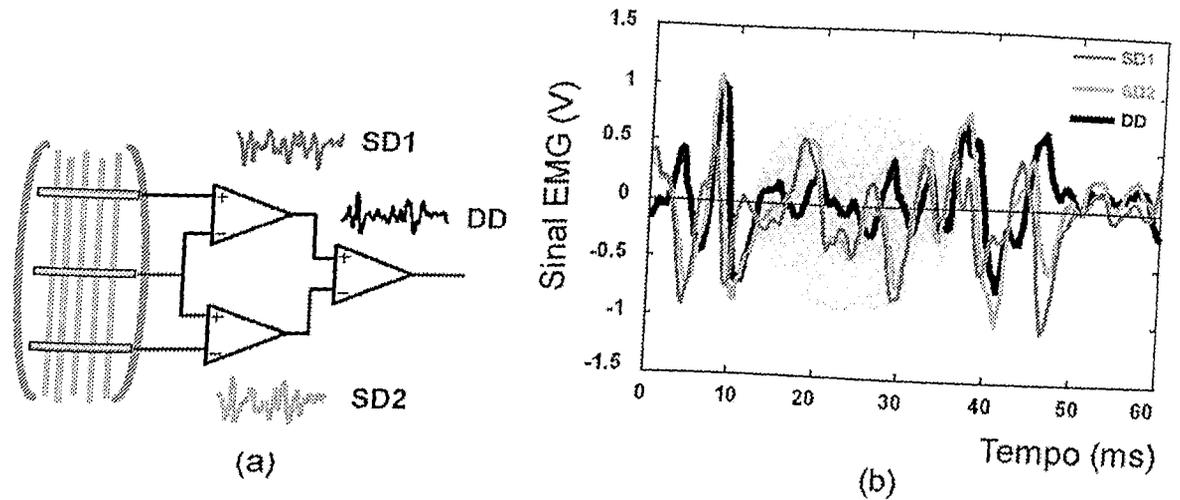


Figura 4.2: Estágio pré-amplificador em eletrodos ativos. (a) Diagrama de um circuito diferencial duplo utilizado na pré-amplificação. (b) Sinais EMG detectados por eletrodos ativos.

Os eletrodos intramusculares são baseados em agulhas e fios (Figura 4.3). As agulhas atravessam a pele e a camada de gordura e são encaixadas nos músculos. Um dos grandes problemas deste tipo de eletrodo é que durante a contração ele pode romper o músculo, dilacerando porções dos tecidos. Já eletrodos baseados em fios implantam, com auxílio de uma agulha, um fino fio no músculo de interesse. O fio é flexível de tal forma a garantir que sua posição não seja alterada e que não ocorram dilacerações nos tecidos.

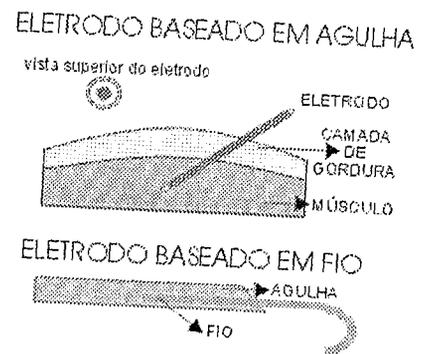


Figura 4.3: Eletrodos intramusculares baseados em agulha e fio.

Além da seleção do tipo de eletrodo adequado, deve-se considerar ainda seu posicionamento na área de interesse. O mal posicionamento dos eletrodos pode implicar na

obtenção de sinais que não representem o fenômeno investigado, podendo provocar, dessa forma, avaliações errôneas. Cram *et al.* (1998) [18] sugerem alguns cuidados a serem tomados no posicionamento de eletrodos:

- O fenômeno de *cross-talk* devido à proximidade entre músculos pode ser minimizado selecionando-se o tamanho adequado dos eletrodos e a separação ideal entre eles;
- É preferível a escolha de áreas que não obstruam a visão ou a movimentação;
- Sempre que possível, os eletrodos devem ser posicionados paralelamente às fibras, maximizando-se dessa forma a sensibilidade e seletividade;
- É preferível a escolha de regiões de fácil localização, ou seja, que possuam boas referências anatômicas, para facilitar o posicionamento dos eletrodos durante os experimentos.

Cram *et al.*, 1998 [18], sugerem ainda alguns cuidados para que possamos comparar valores de sinais eletromiográficos entre músculos e entre indivíduos:

- **Idade e sexo:** estas variáveis possuem um papel substancial no funcionamento fisiológico e por isso devem ser consideradas. Para procedimentos dinâmicos, o nível de recrutamento de fibras cai com o aumento da idade. Isso, provavelmente, é resultado de uma perda de massa muscular devido à inatividade decorrente do aumento da idade. Contudo, estudos revelam que para procedimentos estáticos tais diferenças se tornam irrelevantes. Também não são observadas diferenças significativas em procedimentos estáticos quando se considera o sexo dos indivíduos;
- **Espessura do tecido adiposo subcutâneo:** O tecido adiposo isola e atenua o sinal EMG detectado por eletrodos de superfície. Assim, é importante considerar que a dispersão provocada em diferentes indivíduos é distinta, e portanto, em avaliações comparativas, deve-se realizar a normalização do sinal;
- **Velocidade de contração:** A atividade eletromiográfica varia consideravelmente com a velocidade de contração das fibras musculares. Sendo assim, deve-se buscar uma velocidade padrão (constante) na realização de experimentos isotônicos;

- **Tipo de eletrodo:** Existe uma variedade de tipos de eletrodos disponíveis no mercado: os mais comuns são banhados a ouro, prata, níquel ou estanho. O tipo de eletrodo influencia na qualidade do sinal detectado, sendo que os banhados a ouro, possuem melhor performance na detecção;
- **Estabilidade dos eletrodos:** Quando um eletrodo é colocado sobre a pele, as superfícies de detecção ficam em contato com os eletrólitos da pele. Uma reação química, que requer algum tempo para estabilizar (poucos segundos), é então iniciada. Assim, após a colocação dos eletrodos deve-se aguardar alguns segundos, antes que se possa iniciar a sessão de aquisição de sinais.

4.2.2 Estágio de Condicionamento

O estágio de condicionamento do sinal, representado pelo amplificador diferencial e pelo filtro da Figura 4.1, deve ser projetado considerando-se dois aspectos que interferem na fidelidade do sinal:

- A razão sinal/ruído: razão entre a energia do sinal EMG e a energia do sinal de ruído. Em geral, o ruído é definido como sendo um sinal elétrico que não faz parte do sinal desejado;
- A distorção do sinal: deve ser minimizada de modo que a contribuição relativa de qualquer componente do sinal EMG não seja alterada.

O amplificador diferencial, além de amplificar o sinal, elimina ruídos. Como resultado desta amplificação diferencial, qualquer sinal “comum” presente nos 2 eletrodos (característico de ruídos) será removido e sinais distintos serão amplificados. Qualquer sinal que se origine longe dos pontos de detecção aparecerão como sinais comuns, enquanto que sinais próximos à superfície de detecção serão distintos e, portanto, serão amplificados. Contudo, mesmo com os grandes avanços na eletrônica, é difícil rejeitar estes sinais comuns perfeitamente. A precisão com a qual um amplificador pode eliminar sinais comuns é medida pela Relação de Rejeição em Modo Comum (*Common Mode Rejection Ratio* -

CMRR) do amplificador. Um amplificador diferencial perfeito deve ter uma CMRR infinita. Para suprimir fontes elétricas não desejáveis uma CMRR de 32 a 90 dB é geralmente suficiente. A tecnologia atual permite uma CMRR de 120 dB, mas existem pelo menos três razões para não utilizar um amplificador com essa alta CMRR: 1) tais dispositivos são caros, 2) é difícil mantê-los estáveis e 3) Os sinais não desejáveis podem não chegar em fase nas superfícies de detecção e conseqüentemente eles não serão sinais em “modo comum” (De Luca, 1996) [28].

O filtro deve ser projetado levando-se em consideração a maior parte da energia do sinal EMG que está compreendida na faixa de 20 a 500 Hz. Em geral, utilizam-se filtros Butterworth passa-faixa de 20 Hz a 1 kHz de ordem não muito elevada (por exemplo 2), de modo a não provocar um defasamento no sinal. Além de limitar a faixa do sinal para análise, o filtro tem ainda o papel de eliminar ruídos e evitar *aliasing* sobre o sinal amostrado.

Segundo De Luca (1996) [28] as principais fontes de ruídos que surgem durante o condicionamento de sinais EMG são:

- **Equipamentos eletrônicos responsáveis pela detecção e armazenamento do sinal:** Todo equipamento eletrônico gera ruídos elétricos. Tais ruídos possuem componentes de frequência que variam de 0 Hz a milhares de Hz e não podem ser eliminados completamente. Contudo, podem ser reduzidos com o uso de componentes eletrônicos de alta qualidade e cuidados especiais no projeto e confecção do circuito eletrônico;
- **Ruído ambiente:** Origina-se de fontes de radiações eletromagnéticas, tais como transmissões de rádio e televisão, cabos e fios elétricos, bulbos de lâmpadas, lâmpadas fluorescentes, etc. A frequência dominante neste tipo de ruído é 60 Hz e/ou 50 Hz;
- **Movimentação de artefatos:** Existem duas fontes principais de movimentos de artefatos: 1) a interface entre a superfície de detecção do eletrodo e a pele e 2) movimento dos cabos que conectam os eletrodos ao amplificador. Os sinais elétricos de ambas as fontes possuem a maior parte de sua energia na faixa de frequência

compreendida entre 0 e 20 Hz. Tais ruídos podem ser substancialmente atenuados se os circuitos eletrônicos forem projetados apropriadamente;

- **Instabilidade inerente do sinal:** As componentes de frequências entre 0 e 20 Hz dos sinais EMG são particularmente instáveis, pois são afetadas pela natureza quase randômica da taxa de ativação das unidades motoras que, em geral, são ativadas naquela faixa de frequência. Assim, é aconselhável considerá-las como ruídos indesejáveis e removê-las do sinal a ser analisado.

4.2.3 Estágio de Aquisição

A especificação do estágio de aquisição do sinal deve observar a faixa de frequência da energia predominante do sinal EMG e a quantidade de canais necessários para a realização dos experimentos. Levando-se em conta estas informações são descritas a seguir as principais características do cartão de aquisição de dados utilizado (CIO-DAS 16/330 - *Computer Boards*):

- Conversor A/D de 12 bits;
- Configurações de entrada para 16 canais *single-ended* ou 8 canais diferenciais;
- Amplificador de ganho programável: 1, 2, 4 ou 8 vezes;
- Taxa máxima de aquisição de 330 kHz;
- *Buffer* FIFO com capacidade de 1024 amostras;
- Faixa de entrada de -10 V a +10 V.

4.2.4 Estágio de Janelamento

Este estágio determina o tamanho da janela de análise do sinal EMG, estabelece o início e o fim da atividade eletromiográfica com base em limiares pré-estabelecidos de variância do sinal e subtrai o sinal original de sua média, eliminando assim níveis DC indesejáveis. O processo de janelamento evita ainda informações desnecessárias no

sinal a ser processado, como por exemplo o período que antecede ao início da atividade eletromiográfica.

4.2.5 Estágio de Extração das Características

Este estágio é responsável pela determinação e representação das características do sinal EMG. Ele deve ser projetado de forma que:

- Suas respostas possuam variações mínimas se houverem modificações na posição dos eletrodos;
- Sinais gerados por grupos musculares diferentes sejam representados distintamente;
- O número de informações apresentadas ao sistema de classificação seja reduzido.

4.2.6 Estágio de Classificação

Este estágio de tomada de decisão é o responsável pela associação das características extraídas do sinal EMG a um conjunto classes previamente especificadas, por exemplo, um dos movimentos do cotovelo (extensão e flexão) ou do punho (supinação e pronação).

4.3 Características do Sistema Desenvolvido

4.3.1 Detecção

Apesar de existir pouca informação sobre uma técnica ideal para posicionamento de eletrodos, é importante que se adote uma metodologia correta para que experimentos possam ser repetidos e comparados. Assim, para garantir uma separação constante entre os eletrodos, projetou-se uma base de fixação (Figuras 4.4 e 4.5) que mantém os eletrodos a uma distância fixa de 20 mm entre centros. Note, na Figura 4.5, o detalhe das curvas anatômicas, que proporcionam conforto ao usuário, e dos sulcos, que evitam que o gel se espalhe pela superfície e provoque um curto-circuito entre os eletrodos.

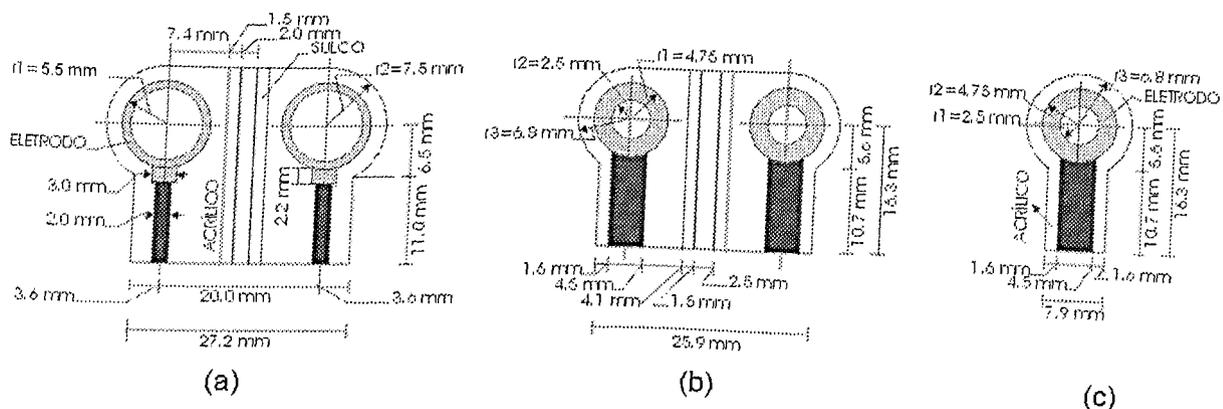


Figura 4.4: Projeto de superfícies de apoio para a fixação de eletrodos. (a) Projeto para eletrodo de raio 5.5 mm. (b) Projeto para eletrodo de raio 4.75 mm. (c) Projeto para eletrodo de referência de raio 4.75mm.

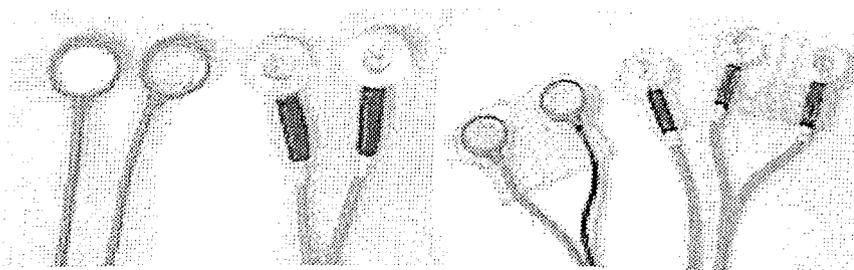


Figura 4.5: Eletrodos de disco antes e após a fixação sobre as superfícies projetadas.

Neste trabalho foram utilizados eletrodos banhados a prata pois são de custo relativamente baixo e propiciam uma representação satisfatória do sinal. Na realização dos experimentos foi realizada abrasão da pele para melhorar a interface eletrodo/pele.

4.3.2 Condicionamento

O eletromiógrafo desenvolvido para a realização dos experimentos neste trabalho é mostrado na Figura 4.6. Ele foi projetado seguindo as recomendações mencionadas anteriormente e possui as seguintes características:

- Aquisição simultânea de até 8 canais diferenciais;
- Terra comum a todos os canais;
- Filtro passa-faixa com faixa de passagem de 20 Hz a 5 kHz;
- Três estágios de amplificação, sendo que o primeiro pode fornecer ganhos de 1, 2 ou 5, o segundo 82, 10, 22 ou 39, e o terceiro 10, 100 ou 1000, possibilitando assim um ganho mínimo de 100 vezes e máximo de 410 mil vezes;
- Isolação óptica - 1.5 kV (rms) a 60 Hz - entre o circuito eletrônico e o estágio que fica em contato com o paciente;
- Impedância de entrada dos canais: 10 GOhms em modo diferencial;
- CMRR: 93 dB a 60 Hz.

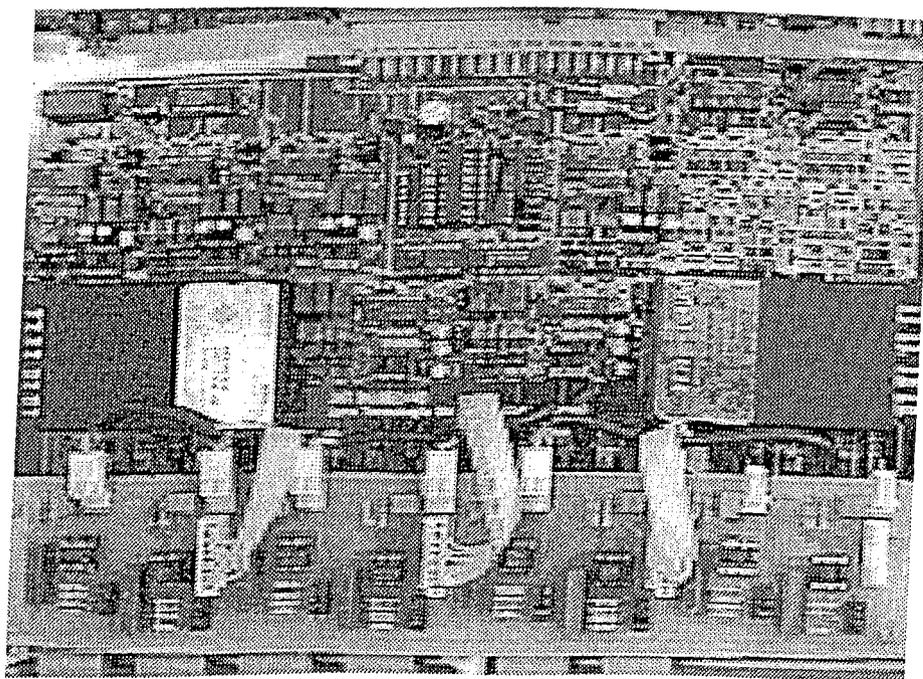


Figura 4.6: Foto do sistema para condicionamento de sinais utilizado nos experimentos.

Como descrito no Capítulo 3, a amplitude do sinal EMG pode variar de 0 a 6 mV (pico-a-pico) ou 0 a 1,5 mV (rms). Para os experimentos descritos no Capítulo 5 o eletromiógrafo foi ajustado para a configuração de ganho de $2 \times 22 \times 100 = 4400$, garantindo

assim, a amplificação necessária para o processo de conversão analógico-digital. Para esta configuração foram obtidas as respostas em frequência de todos os canais do eletromiógrafo. A Figura 4.7 representa a resposta em frequência do canal 0, similar aos demais canais. Observe que o ganho é constante na faixa de frequência de 20 a 1200 Hz, onde concentra-se a maior parte da energia útil do sinal EMG.

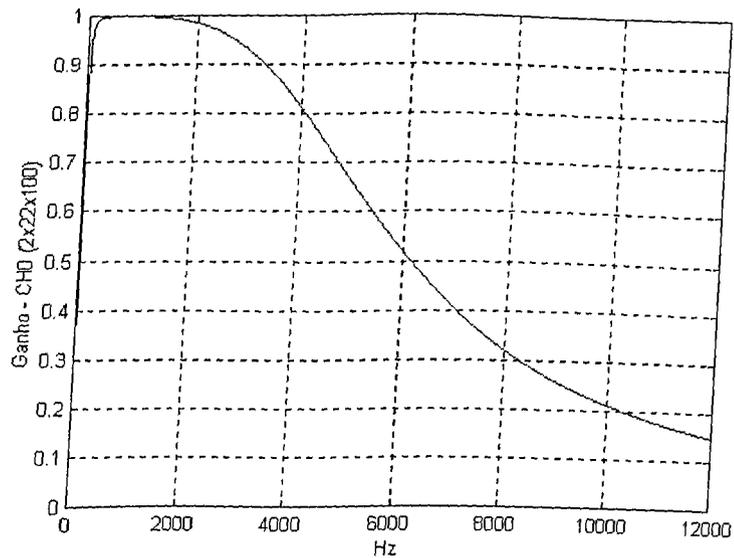


Figura 4.7: Diagrama de Bode para o canal 0 (CH0) do eletromiógrafo.

4.3.3 Aquisição

A interface desenvolvida para configuração dos parâmetros da aquisição, do armazenamento e da visualização dos sinais é mostrada na Figura 4.8. As principais características do *software* desenvolvido são:

- Possibilidade de ajuste do número de canais, da taxa de aquisição e do número de amostras por canal;
- Controle automático do processo de aquisição;
- Possibilidade de armazenamento de dados em formato texto ou binário;

- Ferramenta *Zoom* (Figura 4.9): fornece a visualização independente de cada um dos canais e diversos parâmetros estatísticos dos sinais - média, desvio padrão, variância e valor RMS;
- Ferramenta Matemática Básica (Figura 4.10): permite combinar (somar ou subtrair) os sinais dos diversos canais. Isto pode ser útil na eliminação de ruídos e principalmente na busca de novos padrões para representação de diversos fenômenos.

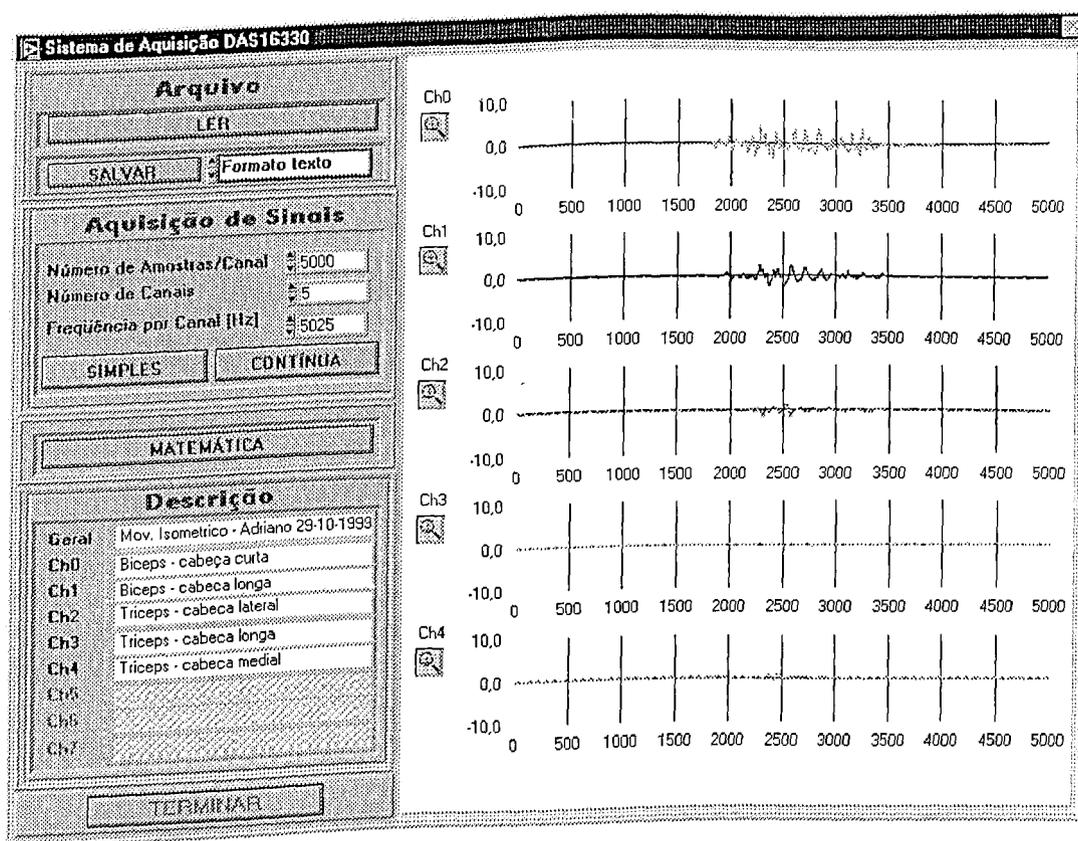


Figura 4.8: Interface principal para controle da aquisição, visualização e armazenamento de sinais.

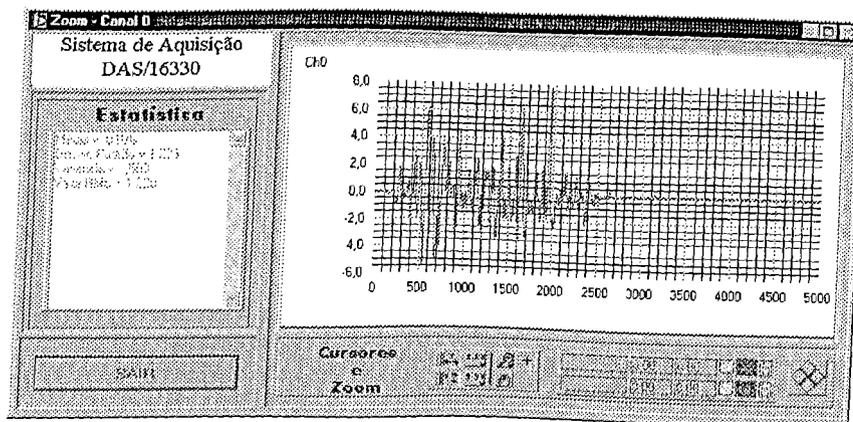


Figura 4.9: Ferramenta *Zoom*.

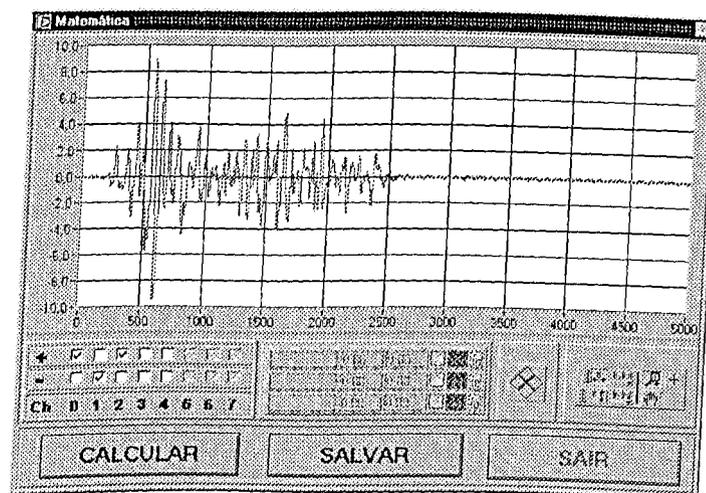


Figura 4.10: Tela de apresentação da Ferramenta Matemática Básica.

4.3.4 Janelamento

A interface gráfica do sistema de janelamento desenvolvido é mostrada na Figura 4.11.

O *software* determina automaticamente o início e o fim da atividade eletromiográfica baseado no tamanho da janela escolhida e nos limiares de variância estabelecidos.

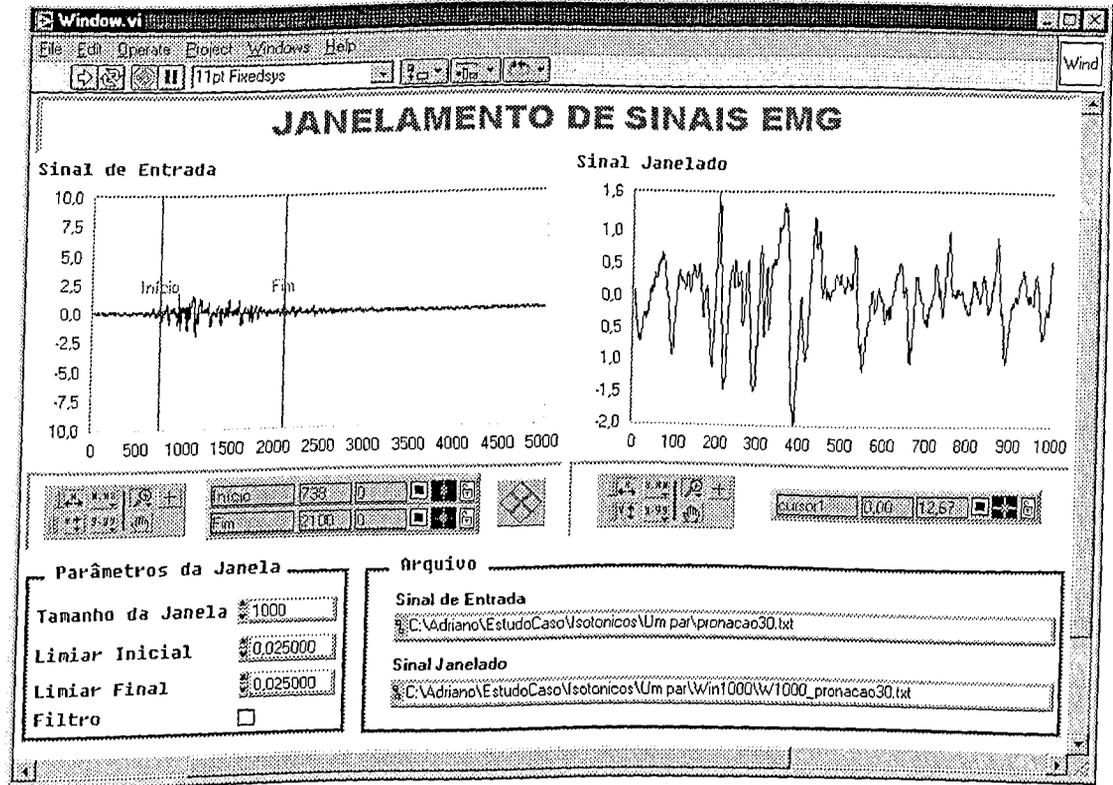


Figura 4.11: Interface gráfica de janelamento de sinais EMG.

4.3.5 Extração das Características

A Figura 4.12 mostra a interface gráfica para o programa desenvolvido. O sistema fornece como resultado os coeficientes do modelo AR e permite a visualização gráfica do sinal janelado, do sinal estimado, da função densidade espectral de potência do sinal, do sinal de erro e da função autocorrelação do sinal de erro. Os gráficos de saída devem então ser utilizados como ferramenta de apoio para verificar se a constante de convergência e a ordem do modelo estão adequadas, ou seja, para verificar se os coeficientes realmente representam o sinal de entrada.

O programa que executa este estágio utiliza o algoritmo para cálculo dos parâmetros do modelo AR apresentado no Capítulo 3 com uma pequena modificação proposta por Veiga *et al.* (2000) [40]): após o término das amostras do sinal de entrada, em vez do processo de atualização dos parâmetros parar, ele é realimentado novamente com o sinal

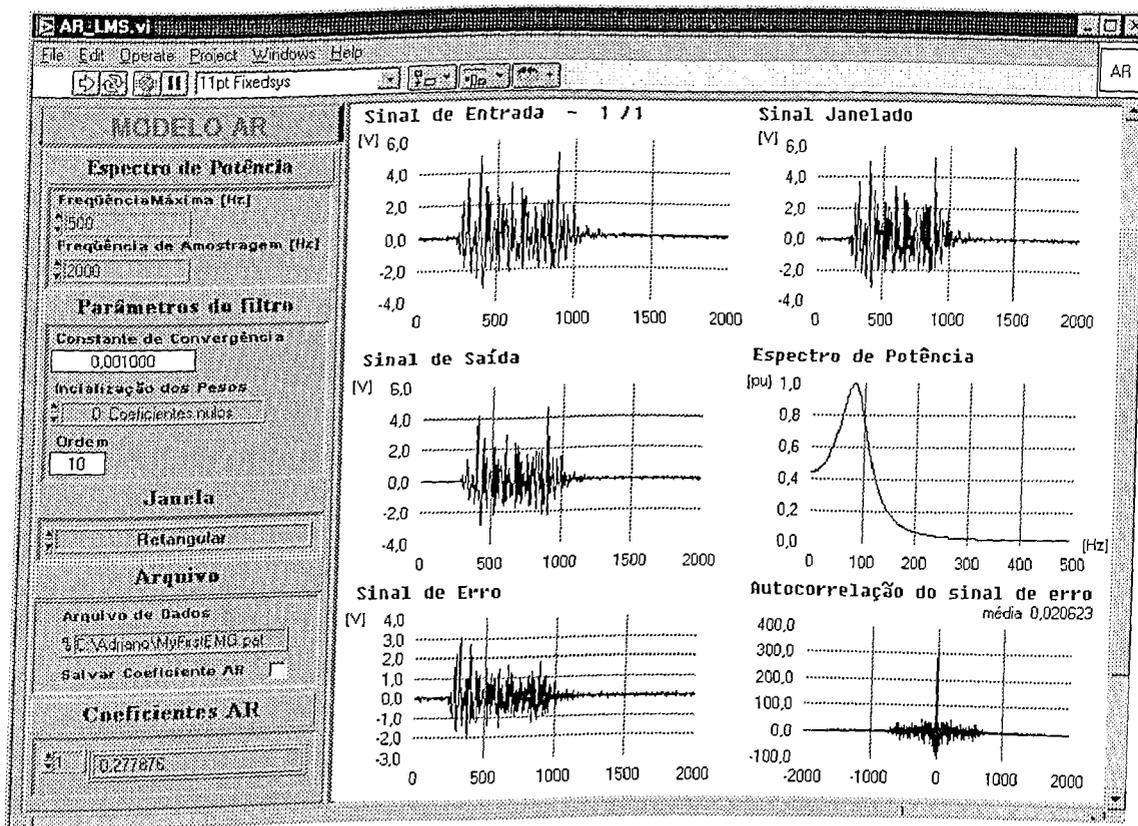


Figura 4.12: Interface gráfica do programa para extração de características.

de entrada mas utilizando-se os parâmetros a_i da iteração anterior, continuando neste ciclo até que um erro mínimo entre o sinal de entrada e o estimado seja atingido, ou até que se atinja um número pré-definido de iterações.

Esta pequena adaptação no algoritmo LMS tradicional torna a determinação dos coeficientes do modelo AR mais independente com relação à constante de convergência do filtro, facilitando assim o processo de convergência e possibilitando um modelamento mais adequado do sinal. O efeito imediato da adoção desta metodologia pode ser observado na Figura 4.13. Na janela sombreada da Figura 4.13a o sinal estimado é comparado com o original. Observe que nesse caso, onde é utilizado o LMS padrão, o sinal estimado está modificado em fase e amplitude com relação ao sinal original. Já na Figura 4.13b, onde utiliza-se o LMS modificado, o sinal estimado aproxima-se bem mais do sinal original.

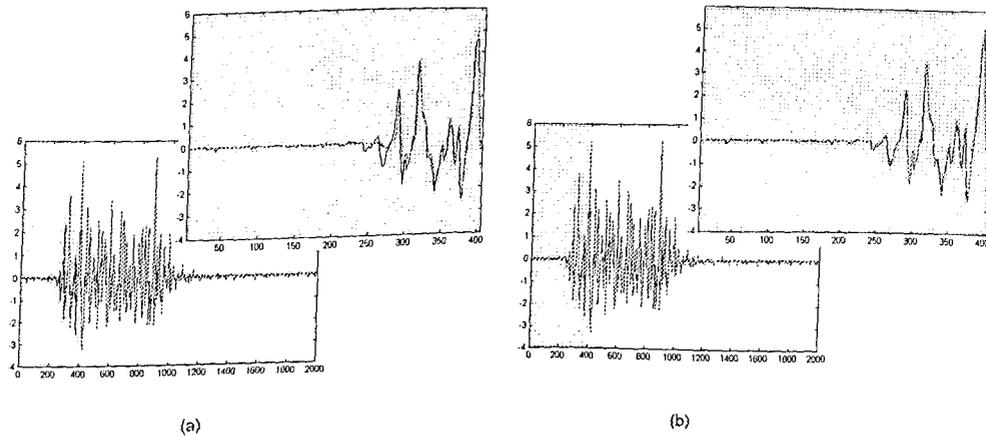


Figura 4.13: (a) Sinal estimado com base no LMS tradicional. Observe através do *zoom* a diferença entre os sinais de entrada e o estimado. (b) Sinal estimado com base no LMS modificado. Observe através do *zoom* a semelhança entre os sinais de entrada e o estimado.

4.3.6 Classificação

Conforme observado na Figura 4.1 a etapa seguinte à extração de características é a classificação das mesmas. Para tal, este trabalho adotou a arquitetura neural MLP (*Multi-Layer Perceptron*), mostrada na Figura 4.14, com n neurônios na camada de entrada, 80 neurônios na camada intermediária e 4 neurônios na camada de saída. O número n de neurônios na camada de entrada é função do número de coeficientes do modelo AR apresentados à rede. Para a etapa de treinamento utilizou-se o algoritmo *Backpropagation*.

A topologia MLP pode conter várias camadas intermediárias porém, o Teorema da Aproximação Universal (Haykin, 1994) [15], especifica que apenas uma camada intermediária é suficiente para garantir que o treinamento da rede MLP possa convergir. Este teorema indica o número de camadas intermediárias, mas não especifica o número de neurônios desta camada, que foi determinado empiricamente de modo a garantir a convergência durante a etapa de treinamento. A escolha pela arquitetura MLP foi baseada no grande sucesso que esse arquitetura vem obtendo em diversas aplicações.

A opção por um algoritmo de treinamento supervisionado se justifica pelo fato de que,

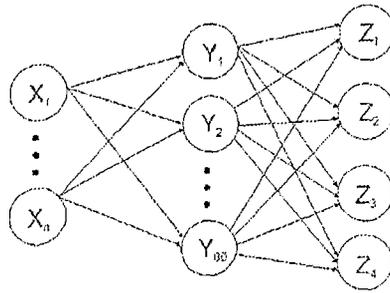


Figura 4.14: Arquitetura neural MLP utilizada.

na aplicação em questão, existe a possibilidade do estabelecimento prévio de exemplos de padrões de sinais EMG, associados a um determinado movimento da prótese. Para o treinamento da rede neural foi utilizado o algoritmo *Backpropagation* (Reidmiller, 1993 [35]) implementado na *toolbox* de redes neurais do sistema Matlab (*The Math Works Inc.*).

4.4 Conclusão

Neste capítulo, descreveu-se o sistema de processamento de sinais EMG desenvolvido. A divisão deste sistema em vários estágios permite-nos verificar que um modelo ideal de processamento é bastante complexo exigindo muita atenção e cuidados especiais em seu projeto.

Capítulo 5

Experimentos e Resultados

5.1 Introdução

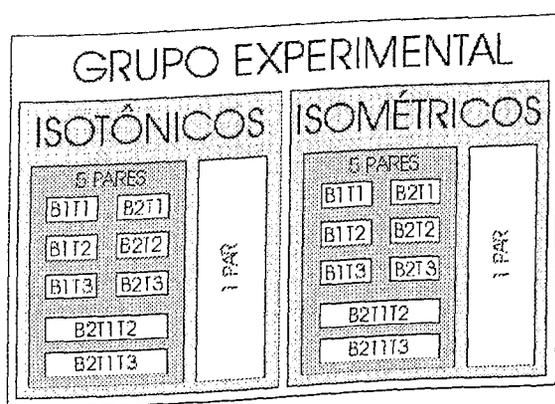


Figura 5.1: Estrutura do grupo experimental.

Neste capítulo, o sistema de processamento de sinais EMG apresentado no Capítulo 4 é avaliado. A Figura 5.1 especifica a estrutura do grupo experimental utilizado. Para avaliação dos resultados obtidos sob diferentes condições, dividiu-se os movimentos em dois sub-grupos: isotônicos e isométricos. Para cada um deles foram utilizadas duas configurações de posicionamento de eletrodos:

- 5 pares, sendo dois sobre o grupo muscular bíceps - na cabeça longa (B1) e na cabeça curta (B2) - e três sobre o grupo muscular tríceps - na cabeça longa (T1), na cabeça medial (T2) e cabeça lateral (T3);
- 1 par situado sobre o plexo braquial.

A configuração de 5 pares (Figura 5.2) baseou-se no trabalho de Sousa (1998) [9], onde cinco sítios, distribuídos sobre o bíceps e o tríceps, são utilizados para detecção do sinal.

A configuração de 1 par (Figura 5.3) foi utilizada como uma tentativa de se avaliar os sinais detectados sobre o plexo braquial, por onde passam os nervos responsáveis pela ativação da maior parte dos grupos musculares do braço. Em ambos os casos adotou-se um eletrodo de referência situado sobre o ombro (Figura 5.4).

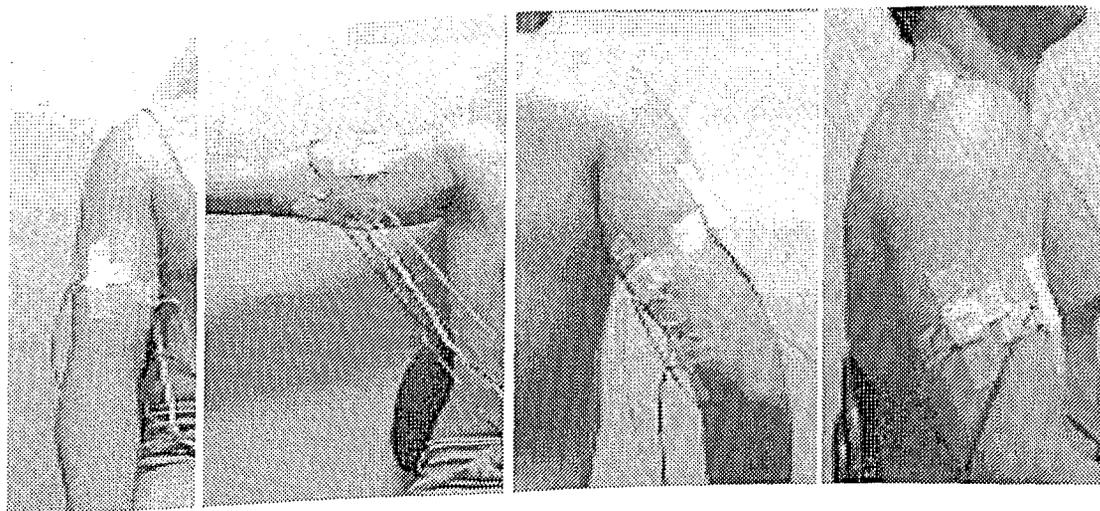


Figura 5.2: Posicionamento dos cinco pares de eletrodos sobre as cabeças do bíceps e do tríceps.

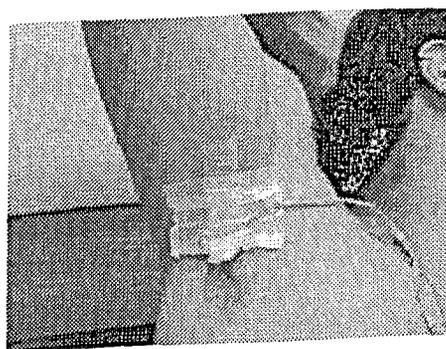


Figura 5.3: Detalhe do posicionamento de par de eletrodos sobre o plexo braquial.



Figura 5.4: Posicionamento do eletrodo de referência sobre o ombro.

Além de avaliações considerando os cinco pares (B1, B2, T1, T2 e T3), foram realizadas ainda análises para combinações de dois pares (B1T1, B1T2, B1T3, B2T1, B2T2 e B2T3) e de três pares (B2T1T2 e B2T1T3) de eletrodos, conforme apresentado na Figura 5.1. Estas combinações tiveram por objetivo a determinação do número mínimo de eletrodos e seu posicionamento para o controle de próteses.

Para cada um dos sub-grupos apresentados na Figura 5.1 analisou-se quatro classes de movimentos do braço: flexão, extensão, pronação e supinação. Observe que a discriminação de quatro classes de movimentos permite controlar uma prótese com quatro graus de liberdade.

5.2 Descrição da Metodologia Experimental

Todo experimento científico requer uma metodologia precisa para que possa ser confiável, repetitivo e submetido a processos de análises e comparações.

Para a realização dos experimentos foi escolhido um indivíduo normal com as seguintes características:

- Idade: 24 anos;
- Altura: 1.80 m;
- Peso: 78 kg;
- Sexo: masculino.

Os movimentos foram realizados tendo em mente a naturalidade dos mesmos, sem a preocupação de se obter uma grande uniformidade em força ou velocidade. Procurou-se, contudo, trabalhar com movimentos de duração máxima de 1 segundo. A digitalização dos sinais se deu a uma taxa de 5 kHz. Para cada uma das quatro classes de movimento em análise foram realizadas, em um único dia, 50 repetições isométricas e 50 isotônicas. As repetições foram sequenciais com intervalos de 10 segundos entre movimentos de uma mesma classe e com intervalo de 2 minutos entre mudanças de classes. Estes intervalos foram estabelecidos para evitar fadiga muscular.

Para a realização de contrações isométricas foi projetado um aparato experimental (Figura 5.5) cuja a finalidade é fornecer apoio e resistência contrária ao movimento, garantindo assim que as fibras musculares permaneçam em condições isométricas. O aparato atua também como um filtro mecânico, eliminando a movimentação de cabos e sua consequente geração de ruídos. As dimensões foram determinadas para um braço de comprimento máximo de 80 cm, ajustável e com largura máxima de 12 cm.

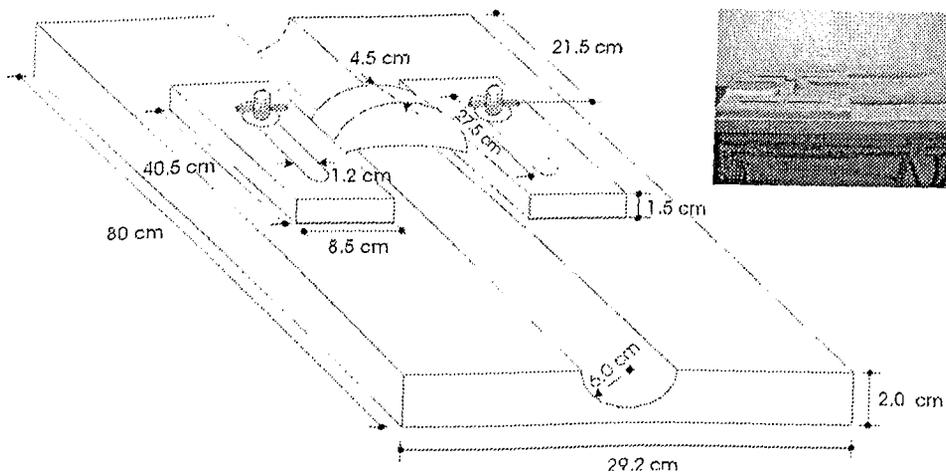


Figura 5.5: Projeto de aparato experimental para aquisição de sinais provenientes de contrações isométricas.

Durante a realização de contrações isotônicas, optou-se por um posicionamento ideal para o braço, conforme mostrado na Figura 5.6. A Figura 5.6a ilustra as posições inicial

e final para os movimentos flexão e extensão e as Figuras 5.6b e 5.6c ilustram a posição final para os movimentos supinação e pronação respectivamente. Todos os movimentos foram inicializados a partir de posições de descanso absoluto do braço.

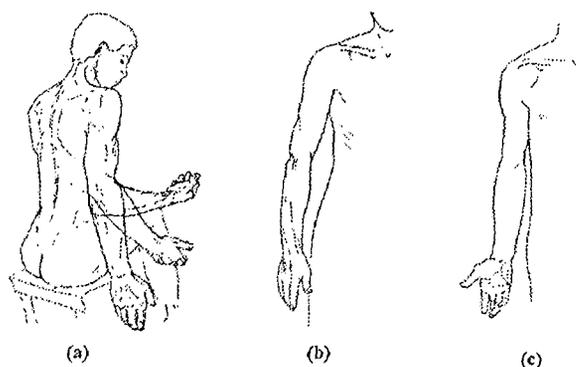


Figura 5.6: Contrações isotônicas (Calais-German, 1991) [2]. (a) Movimentos de flexão e extensão dos cotovelos. (b) Movimento de supinação do punho. (c) Movimento de pronação do punho.

Após detectados e aquisitionados, os sinais EMG foram janelados através da técnica de janelamento descrita no Capítulo 4. O tamanho da janela adotada para análise foi de 200 ms ou 1000 amostras a partir do início da atividade muscular. O limiar inferior de variância utilizado foi de 0.025 para contrações isotônicas e de 0.015 para contrações isométricas, sendo que a escolha desses valores foi feita de maneira heurística, ou seja, após a análise de todos os sinais, obteve-se aqueles valores de variância como os mínimos necessários para garantir uma detecção correta do início da atividade eletromiográfica. Note que o valor do limiar de variância adotado para as contrações isotônicas é superior ao das contrações isométricas. Isto ocorreu pois, durante contrações isotônicas, a razão sinal/ruído decresce, visto que o movimento de cabos provoca um ruído de artefato que é praticamente inexistente em contrações isométricas.

A etapa seguinte à de janelamento foi a normalização. Seu objetivo foi:

- Proporcionar a comparação entre sinais de uma mesma classe ou mesmo de classes diferentes e de diferentes indivíduos;

- Facilitar o processo de convergência nas etapas de extração de características e classificação.

O processo de normalização utilizado foi linear, restringindo a amplitude do sinal em valores compreendidos entre 1 e -1. Foram realizadas normalizações separadas para cada um dos 4 grupos. Para a conversão de escala adotou-se a Equação 5.1, onde X representa uma matriz cujas linhas são os sinais de um determinado grupo e Y é a matriz representando o sinal normalizado.

$$Y = \frac{X - offset}{scale} \quad (5.1)$$

$$scale = 0.5(max(X) - min(X)) \quad (5.2)$$

$$offset = min(X) + 0.5scale \quad (5.3)$$

Os valores de $scale$ e $offset$ para cada um dos grupos são apresentados na Tabela 5.1.

Grupo Experimental	Scale	Offset
Isométrico - cinco pares	8.7735	0.4775
Isotônico - cinco pares	8.3020	-0.3300
Isométrico - um par	4.97500	0.6090
Isotônico - um par	7.1925	-0.6505

Tabela 5.1: Valores de $scale$ e $offset$ para os grupos experimentais.

Depois de normalizados, foram extraídas as características dos sinais, pelo cálculo dos parâmetros do modelo AR, utilizando o algoritmo sugerido por Veiga *et al.* [40]. A constante de convergência utilizada foi de 0.1, sendo que este valor garantiu a convergência no modelamento. Para efeitos comparativos foram calculados modelos de ordem 10, 8, 6, 4 e 3.

Finalmente, realizou-se o processo de classificação das características do sinal. Tal processo dividiu-se basicamente em duas etapas: treinamento e execução. Para cada uma

delas foram determinados grupos de 25 padrões de treinamento e 25 de execução, para cada uma das 4 classes de movimento em análise. A escolha dos padrões para cada um dos grupos foi realizada aleatoriamente, porém observou-se a exclusividade de padrões a cada um deles, ou seja, um determinado padrão só poderia pertencer a um determinado grupo (ou de treinamento ou de execução). O grupo de treinamento procurou representar as características gerais do universo de discurso em questão. Isto implicou em dispor os vários exemplos de cada classe de movimento para treinamento da rede (Observe que a generalização é uma das mais importantes características da redes neurais artificiais e o principal fator que determina uma ótima generalização é o conjunto de treinamento).

Durante o treinamento foram utilizados dois critérios alternativos de parada: um erro mínimo quadrático total de 0.01 ou 100 épocas. Note que não é desejável a obtenção de um erro mínimo igual a zero, visto que isso poderia diminuir o grau de generalização da rede. Os parâmetros de treinamento foram:

- Taxa de aprendizagem fixa em 0.01;
- Momento fixo em 0;
- Função de ativação sigmóide binária, tanto para a camada de entrada quanto para a de saída;
- Inicialização aleatória (valores entre 0 e 1) dos pesos;
- Apresentação aleatória dos padrões de treinamento à rede.

Para cada par de treinamento (padrão - alvo), adotou-se os vetores alvos mostrados na Tabela 5.2.

Tendo em mãos a rede neural devidamente treinada, pode-se avaliar sua performance através da fase de execução. Os resultados obtidos nesta avaliação são apresentados a seguir.

V1	V2	V3	V4
1	0	0	0
0	1	0	0
0	0	1	0
0	0	0	1

Tabela 5.2: Representação dos vetores alvos. V1 representa o alvo para a classe de extensão, V2 para a classe de flexão, V3 para a classe de supinação e V4 para a classe de pronação.

5.3 Apresentação e Discussão dos Resultados

Conforme mencionado anteriormente, os resultados apresentados nesta seção levam em conta:

- O tipo de contração (isométrica ou isotônica);
- O número de pares de eletrodos (1 ou 5);
- O número de parâmetros do modelo AR (10, 8, 6, 4 ou 3).

Através dos coeficientes AR obtidos a partir dos sinais EMG, pode-se determinar suas superfícies. As Figuras 5.7 a 5.11, 5.12 a 5.16, 5.17 a 5.21 e 5.22 a 5.26 são respectivamente as superfícies obtidas para os grupos Isotônico - cinco pares, Istônico - um par, Isométrico - cinco pares e Isométrico - um par. Nestes gráficos o eixo **Coefficientes** indica o número de parâmetros do modelo AR (que no caso de 5 pares de eletrodos sempre vai estar multiplicado por 5), o eixo **Padrões** indica o número de padrões em análise e o eixo **Amplitude dos Coeficientes** contém os valores calculados para os coeficientes. Os padrões de 1 a 50 pertencem à classe extensão, os de 51 a 100 à flexão, os de 101 a 150 à supinação e os de 151 a 200 à pronação. Para o caso de 5 pares de eletrodos o conjunto dos 5m coeficiente, onde m é a ordem do modelo AR, possui o seguinte significado:

- Coeficientes de 1 a m: coeficientes relativos ao sítio B1;

- Coeficientes de $m+1$ a $2m$: coeficientes relativos ao sítio B2;
- Coeficientes de $2m+1$ a $3m$: coeficientes relativos ao sítio T1;
- Coeficientes de $3m+1$ a $4m$: coeficientes relativos ao sítio T2;
- Coeficientes de $4m+1$ a $5m$: coeficientes relativos ao sítio T3.

Observe em cada uma das superfícies a separabilidade de classes representada pela mudança na forma das mesmas. Esse fator é fundamental para que o processo de classificação possa ocorrer mais facilmente. À medida que o número de coeficientes aumenta as superfícies indicam uma maior distinção entre classes. Porém, note que existe um limite (10 coeficientes) a partir do qual este aumento é indiferente, ou seja produz variações mínimas na forma da superfície, e apenas exigirá maior tempo de processamento do sinal.

Comparando-se as superfícies para um par de eletrodos e para cinco pares de eletrodos pode-se concluir que, pelo menos visualmente, as de cinco pares fornecem uma maior separabilidade de classes. Este fato pode ser justificado pelo maior número de informações presente na última situação.

Superfície AR - Grupo Isotônico - Cinco Pares

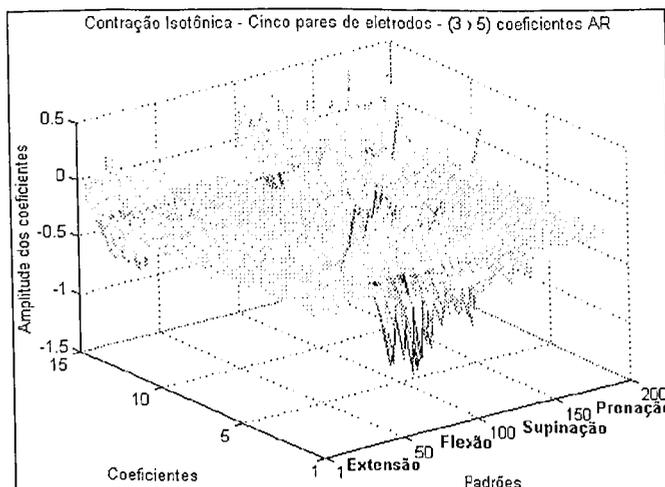


Figura 5.7: Superfície AR com (3x5) coeficientes para o grupo Isotônico - cinco pares.

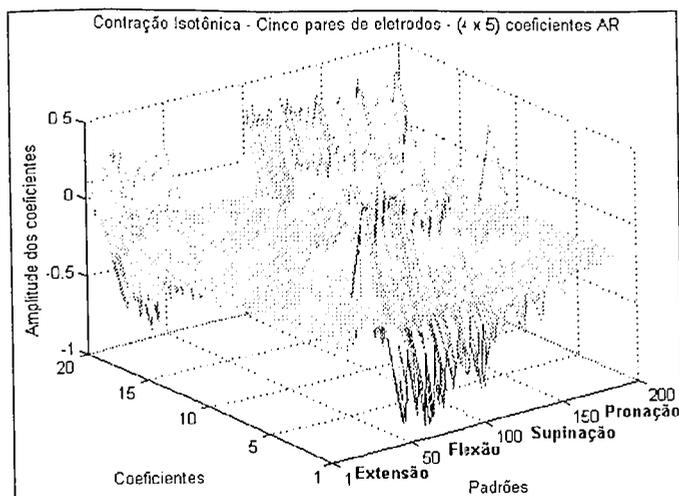


Figura 5.8: Superfície AR com (4x5) coeficientes para o grupo Isotônico - cinco pares.

Superfície AR - Grupo Isotônico - Cinco Pares

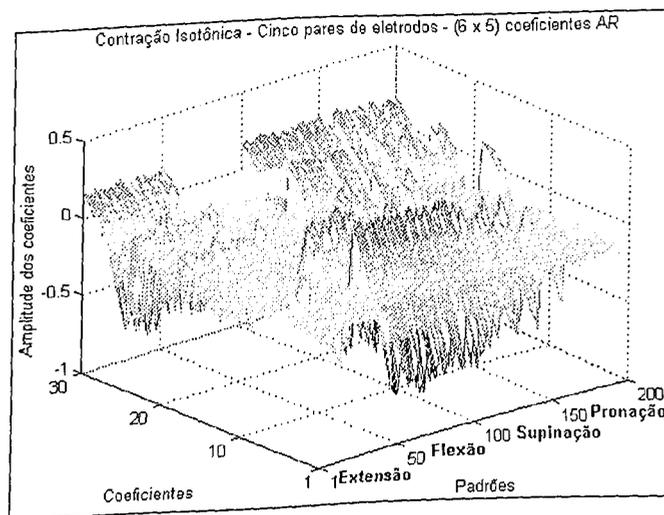


Figura 5.9: Superfície AR com (6x5) coeficientes para o grupo Isotônico - cinco pares.

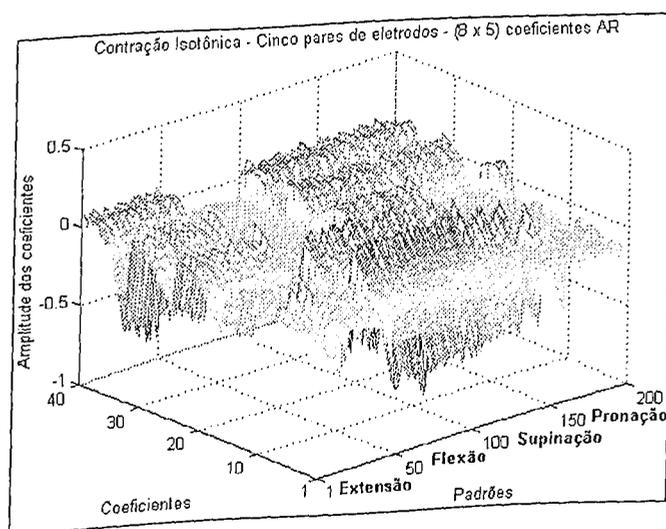


Figura 5.10: Superfície AR com (8x5) coeficientes para o grupo Isotônico - cinco pares.

Superfície AR - Grupo Isotônico - Cinco Pares

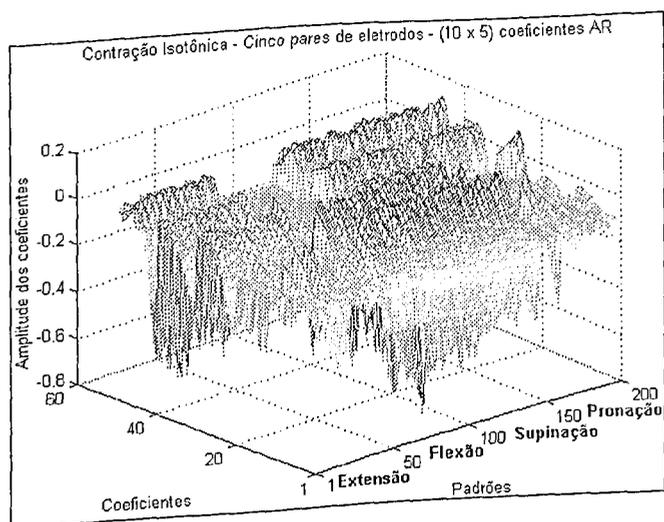


Figura 5.11: Superfície AR com (10x5) coeficientes para o grupo Isotônico - cinco pares.

Através das superfícies obtidas para contrações isotônicas, podemos notar que para o caso de 5 pares de eletrodos os coeficientes realmente proporcionam uma boa separabilidade entre classes, sendo que esta separabilidade é incrementada à medida que o número de coeficientes aumentam.

Superfície AR - Grupo Isotônico - Um Par

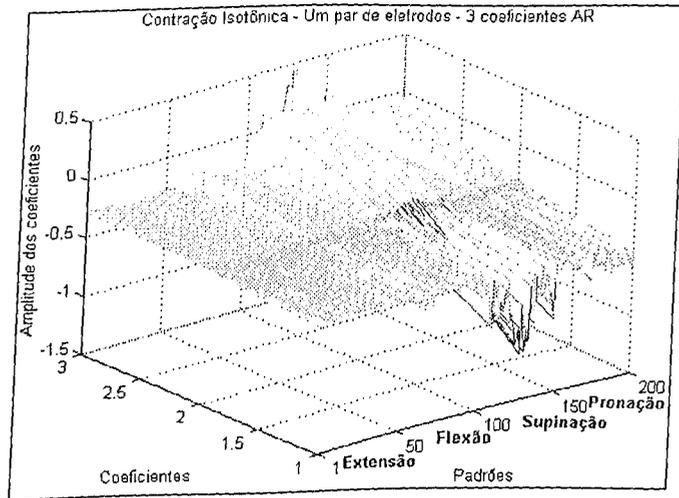


Figura 5.12: Superfície AR com 3 coeficientes para o grupo Isotônico - um par.

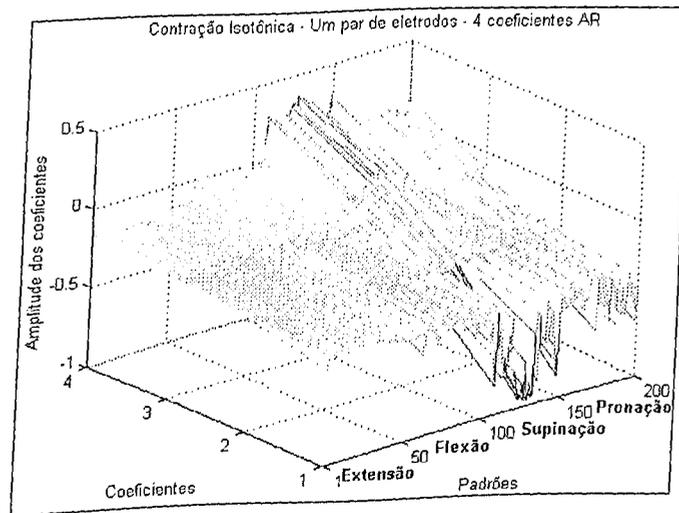


Figura 5.13: Superfície AR com 4 coeficientes para o grupo Isotônico - um par.

Superfície AR - Grupo Isotônico - Um Par

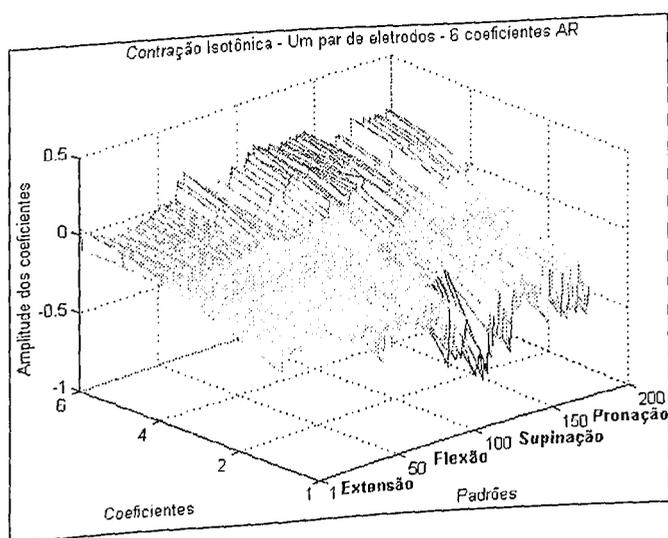


Figura 5.14: Superfície AR com 6 coeficientes para o grupo Isotônico - um par.

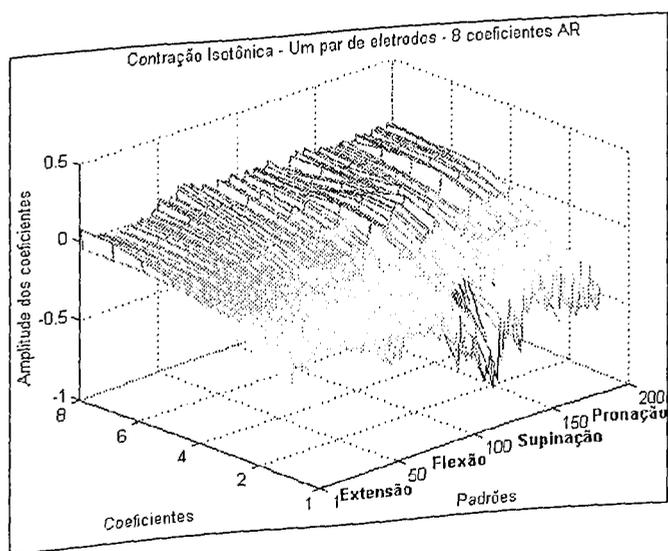


Figura 5.15: Superfície AR com 8 coeficientes para o grupo Isotônico - um par.

Superfície AR - Grupo Isotônico - Um Par

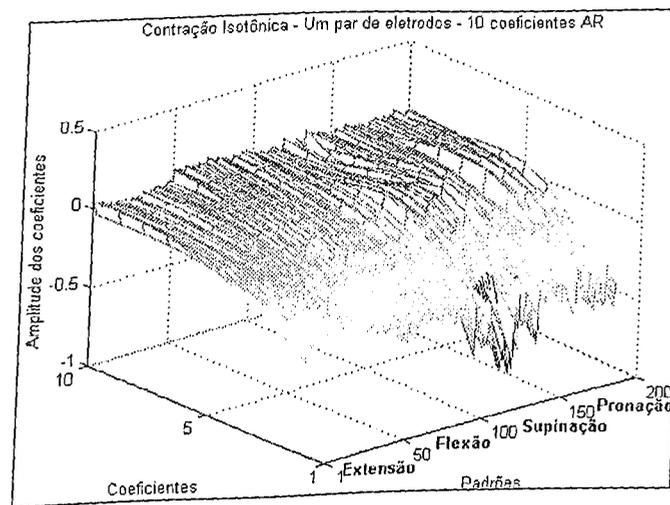


Figura 5.16: Superfície AR com 10 coeficientes para o grupo Isotônico - um par.

As superfícies obtidas para contrações isotônicas e um par de eletrodos indicam uma dificuldade em separação de classes através dos coeficientes do modelo AR.

Superfície AR - Grupo Isométrico - Cinco Pares

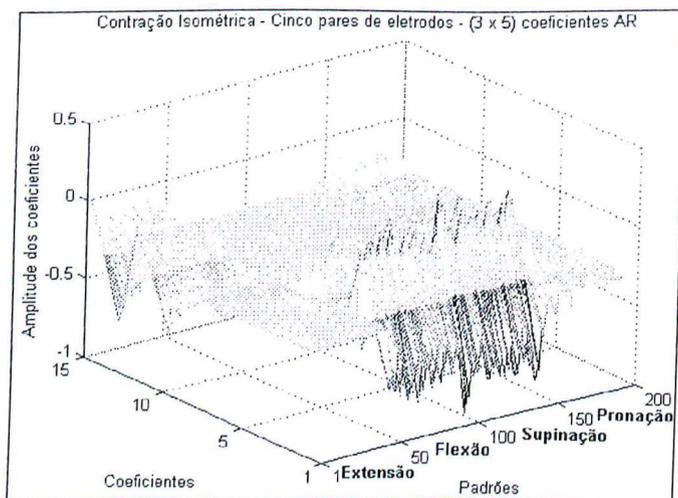


Figura 5.17: Superfície AR com (3x5) coeficientes para o grupo Isométrico - cinco pares.

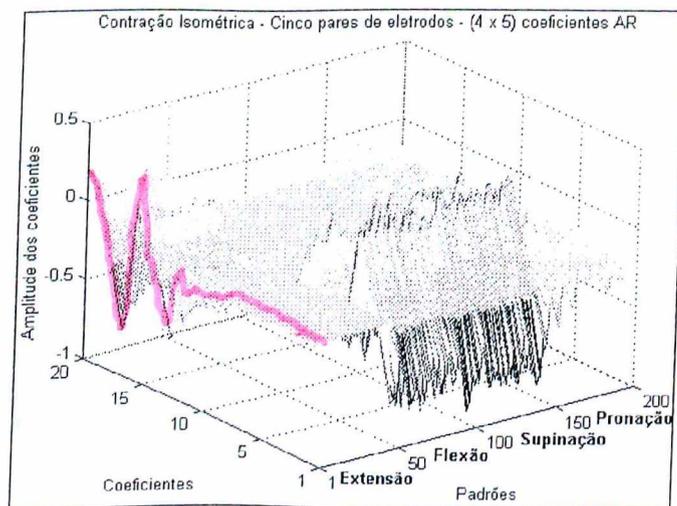


Figura 5.18: Superfície AR com (4x5) coeficientes para o grupo Isométrico - cinco pares.

Superfície AR - Grupo Isométrico - Cinco Pares

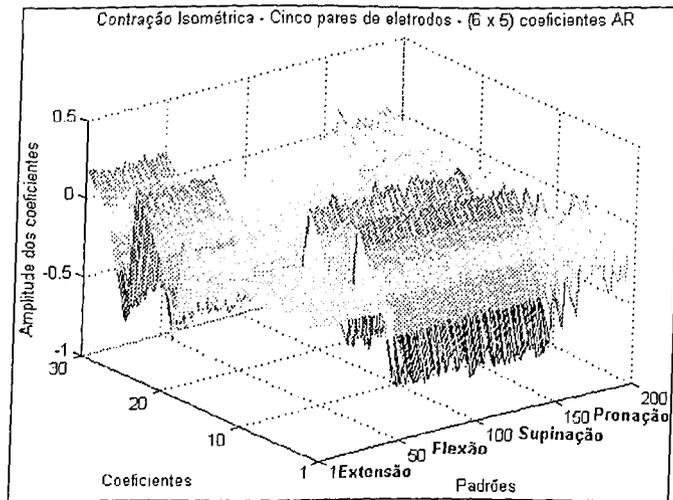


Figura 5.19: Superfície AR com (6x5) coeficientes para o grupo Isométrico - cinco pares.

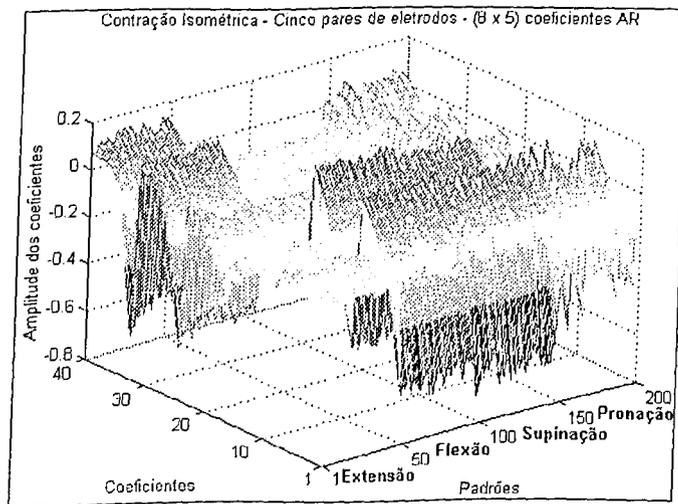


Figura 5.20: Superfície AR com (8x5) coeficientes para o grupo Isométrico - cinco pares.

Superfície AR - Grupo Isométrico - Cinco Pares

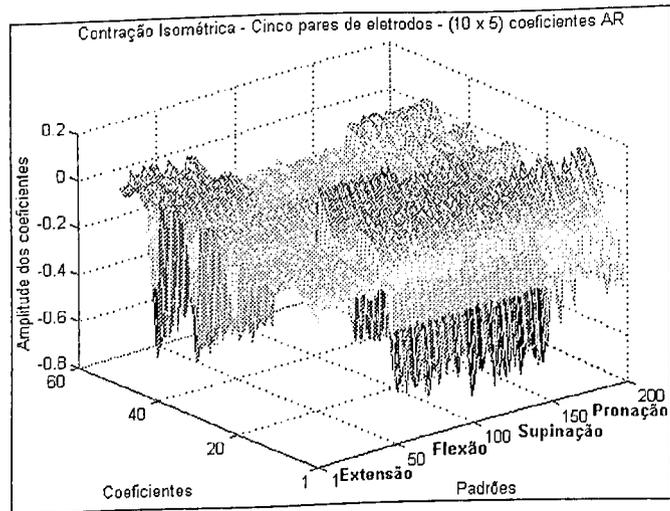


Figura 5.21: Superfície AR com (10x5) coeficientes para o grupo Isométrico - cinco pares.

As superfícies AR indicam que para o caso de contrações isométricas e 5 pares de eletrodos, os coeficientes do modelo AR determinam uma boa separabilidade entre classes.

Superfície AR - Grupo Isométrico - Um Par

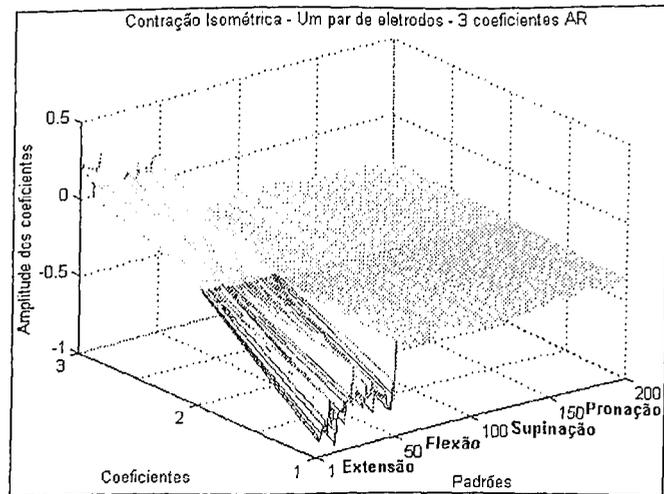


Figura 5.22: Superfície AR com 3 coeficientes para o grupo Isométrico - um par.

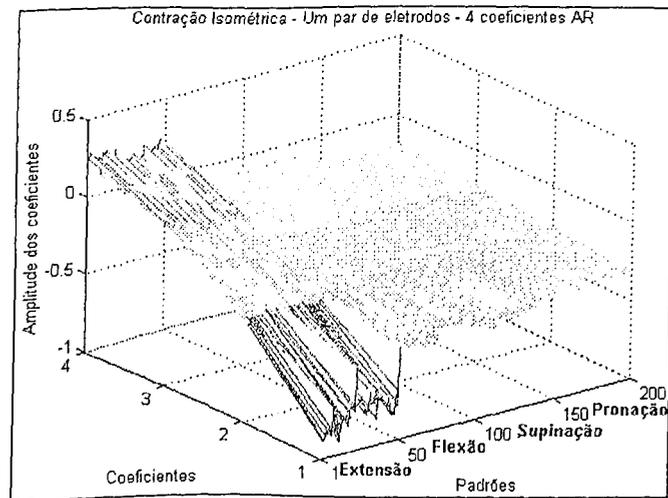


Figura 5.23: Superfície AR com 4 coeficientes para o grupo Isométrico - um par.

Superfície AR - Grupo Isométrico - Um Par

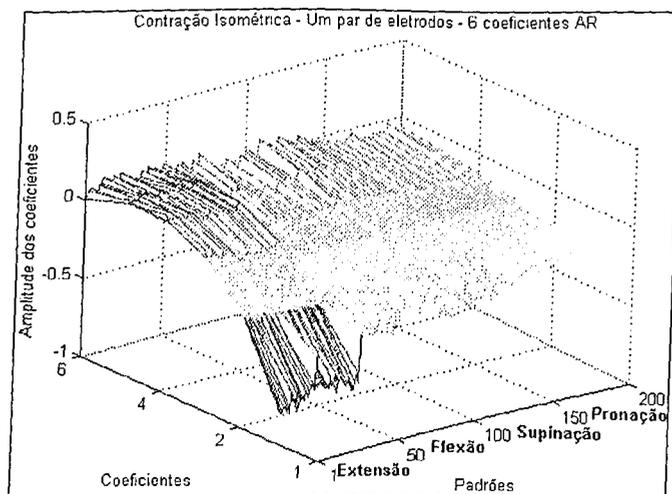


Figura 5.24: Superfície AR com 6 coeficientes para o grupo Isométrico - um par.

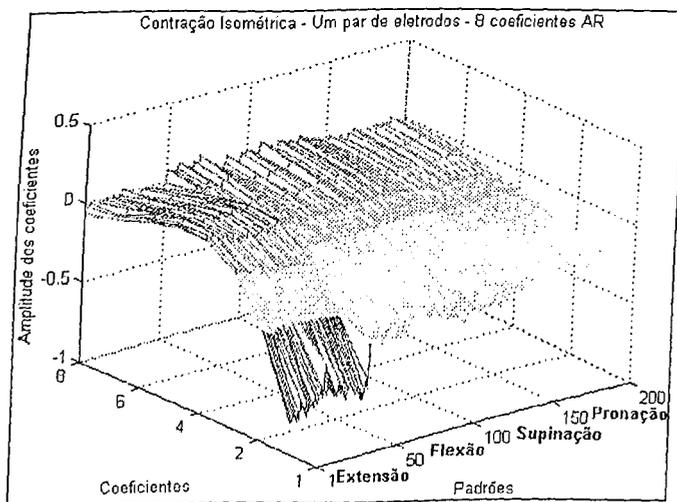


Figura 5.25: Superfície AR com 8 coeficientes para o grupo Isométrico - um par.

Superfície AR - Grupo Isométrico - Um Par

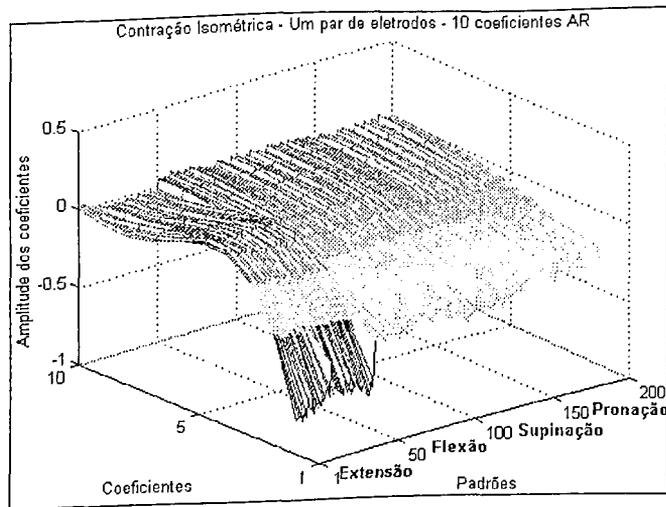


Figura 5.26: Superfície AR com 10 coeficientes para o grupo Isométrico - um par.

As superfícies AR para contrações isométricas e um par de eletrodos indicam uma certa dificuldade em separação de classes através dos coeficientes do modelo AR.

Na classificação do sinal, um determinado padrão foi considerado correto, tanto durante a etapa de treinamento quanto na de execução, se a distância (MSE) entre a resposta da saída da rede e seu respectivo alvo fosse menor ou igual a 0.01. Com base nesta informação, as Tabelas 5.3, 5.4, 5.5 e 5.6 apresentam os resultados para a etapa de treinamento e de execução, referentes aos grupos Isotônico - cinco pares e Isométrico - cinco pares. Tais resultados são percentuais, sendo que 100 % implica que foram acertados 25 padrões.

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	100%	100%	100%	96%
Flexão	100%	100%	100%	100%	100%
Supinação	100%	100%	100%	96%	100%
Pronação	100%	100%	96%	100%	100%
Acerto Médio	100%	100%	99%	99%	99%

Tabela 5.3: Grupo de Treinamento - Isotônico - 5 pares

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	84%	100%	96%	96%	92%
Flexão	100%	92%	100%	100%	100%
Supinação	100%	92%	100%	92%	96%
Pronação	96%	92%	92%	96%	84%
Acerto Médio	95%	94%	97%	96%	93%

Tabela 5.4: Grupo de Execução - Isotônico - 5 pares

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	100%	100%	100%	100%
Flexão	100%	100%	100%	100%	92%
Supinação	100%	100%	100%	100%	96%
Pronação	100%	100%	96%	100%	96%
Acerto Médio	100%	100%	99%	100%	96%

Tabela 5.5: Grupo de Treinamento - Isométrico - 5 pares

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	100%	100%	100%	96%
Flexão	100%	100%	92%	92%	88%
Supinação	100%	100%	100%	100%	84%
Pronação	100%	100%	96%	92%	100%
Acerto Médio	100%	100%	97%	96%	92%

Tabela 5.6: Grupo de Execução - Isométrico - 5 pares

Os resultados indicam, neste caso, que a rede neural teve grande facilidade para realizar a separação de classes e a generalização dos padrões. Note que os modelos de ordem 4, 6, 8 ou 10 mostraram-se adequados para uma boa representação das classes de movimentos. Para o caso dos modelos de ordem 3, o que se observa é uma facilidade durante o processo de treinamento, ou seja, a rede consegue aprender bem os padrões a ela apresentados, porém durante a etapa de execução nota-se uma perda de generalização. Isto representa uma dificuldade no modelamento do sinal utilizando-se apenas três parâmetros.

As avaliações para a etapa de treinamento e de execução dos grupos Isotônico - um par e Isométrico - um par estão apresentados nas Tabelas 5.7, 5.8, 5.9 e 5.10. Como pode ser

observado, a rede teve muita dificuldade em separar os padrões em quatro classes distintas. Note que, para o caso de 3 coeficientes, ela só conseguiu separá-los em 2 classes distintas. Com o aumento do número de coeficientes o processo de treinamento foi facilitado, porém a rede perdeu em generalização. Isso foi devido à proximidade dos coeficientes a ela apresentados. Esse fato já foi observado na análise das superfícies AR mostradas nas Figuras 5.12 a 5.16 e 5.22 a 5.26.

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	88%	100%	84%	84%	0%
Flexão	96%	92%	80%	64%	0%
Supinação	68%	72%	72%	56%	24%
Pronação	88%	80%	64%	64%	100%
Acerto Médio	85%	86%	75%	67%	31%

Tabela 5.7: Grupo de Treinamento - Isotônico - 1 par

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	84%	84%	52%	0%
Flexão	84%	84%	84%	48%	0%
Supinação	72%	48%	56%	60%	40%
Pronação	48%	80%	44%	60%	100%
Acerto Médio	76%	74%	67%	55%	35%

Tabela 5.8: Grupo de Execução - Isotônico - 1 par

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	100%	100%	100%	100%
Flexão	84%	52%	48%	16%	0%
Supinação	84%	76%	68%	72%	0%
Pronação	88%	80%	80%	92%	100%
Acerto Médio	89%	77%	74%	70%	50%

Tabela 5.9: Grupo de Treinamento - Isométrico - 1 par

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	96%	100%	96%	100%	96%
Flexão	48%	56%	24%	20%	0%
Supinação	80%	60%	48%	76%	0%
Pronação	64%	84%	96%	92%	100%
Acerto Médio	72%	75%	66%	72%	49%

Tabela 5.10: Grupo de Execução - Isométrico - 1 par

Os resultados referentes à configuração B1T1 são apresentados nas Tabelas 5.11, 5.12, 5.13 e 5.14. Avaliando-se a etapa de treinamento, observa-se que os resultados indicam uma certa facilidade da rede em realizar a separação dos coeficientes em classes. Note porém, que para o caso de contrações isométricas e modelo de ordem 8, a separação dos padrões em quatro classe distintas não ocorreu. Esse resultado poderia ter sido melhorado realizando-se um novo treinamento, porém pretendeu-se apresentá-lo para ilustrar um dos problemas existentes nos classificadores neurais: a maneira como os pesos são inicializados influencia diretamente no processo de convergência do treinamento.

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	92%	84%	92%	88%	88%
Flexão	100%	100%	100%	100%	100%
Supinação	96%	100%	96%	96%	92%
Pronação	96%	96%	96%	96%	96%
Acerto Médio	96%	95%	96%	95%	94%

Tabela 5.11: Grupo de Treinamento - Isotônico - B1T1

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	84%	96%	80%	84%	84%
Flexão	96%	100%	96%	96%	100%
Supinação	96%	84%	100%	92%	100%
Pronação	96%	100%	92%	100%	96%
Acerto Médio	93%	95%	92%	93%	95%

Tabela 5.12: Grupo de Execução - Isotônico - B1T1

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	0%	92%	88%	100%
Flexão	100%	100%	96%	96%	88%
Supinação	100%	100%	100%	100%	100%
Pronação	92%	100%	84%	80%	92%
Acerto Médio	98%	75%	93%	91%	95%

Tabela 5.13: Grupo de Treinamento - Isométrico - B1T1

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	96%	0%	92%	92%	96%
Flexão	96%	100%	100%	92%	100%
Supinação	100%	100%	96%	100%	96%
Pronação	68%	96%	96%	84%	80%
Acerto Médio	90%	74%	96%	92%	93%

Tabela 5.14: Grupo de Execução - Isométrico - B1T1

As Tabelas 5.15, 5.16, 5.17 e 5.18 apresentam os resultados para a configuração B1T2. Neste caso a rede apresentou uma certa dificuldade em realizar a separação dos coeficientes em quatro classes. Observe porém, que para o caso de contrações isotônicas e 6 coeficientes, a separação foi realizada com sucesso, porém a consequência disso foi uma perda em generalização.

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	88%	92%	92%	92%	0%
Flexão	100%	100%	100%	100%	76%
Supinação	100%	96%	96%	96%	64%
Pronação	92%	76%	96%	48%	100%
Acerto Médio	95%	91%	96%	84%	60%

Tabela 5.15: Grupo de Treinamento - Isotônico - B1T2

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	64%	80%	80%	84%	0%
Flexão	100%	100%	96%	100%	68%
Supinação	96%	92%	100%	84%	52%
Pronação	92%	52%	92%	60%	96%
Acerto Médio	88%	81%	92%	82%	54%

Tabela 5.16: Grupo de Execução - Isotônico - B1T2

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	100%	100%	0%	0%
Flexão	80%	72%	80%	76%	76%
Supinação	68%	60%	60%	72%	64%
Pronação	100%	100%	100%	100%	100%
Acerto Médio	87%	83%	85%	62%	60%

Tabela 5.17: Grupo de Treinamento - Isométrico - B1T2

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	100%	100%	0%	0%
Flexão	68%	72%	88%	76%	68%
Supinação	72%	60%	68%	60%	52%
Pronação	96%	100%	92%	96%	96%
Acerto Médio	84%	83%	87%	58%	54%

Tabela 5.18: Grupo de Execução - Isométrico - B1T2

Os resultados para a configuração B1T3 são mostrados nas Tabelas 5.19, 5.20, 5.21 e 5.22. Estes indicam uma grande dificuldade da rede em separação e generalização de classes.

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	76%	44%	60%	60%	96%
Flexão	100%	100%	100%	100%	72%
Supinação	100%	100%	100%	100%	52%
Pronação	84%	88%	76%	72%	88%
Acerto Médio	90%	83%	84%	83%	77%

Tabela 5.19: Grupo de Treinamento - Isotônico - B1T3

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	52%	72%	68%	64%	96%
Flexão	100%	100%	96%	100%	84%
Supinação	96%	92%	84%	96%	60%
Pronação	72%	76%	52%	60%	100%
Acerto Médio	80%	85%	75%	80%	85%

Tabela 5.20: Grupo de Execução - Isotônico - B1T3

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	100%	100%	100%	96%
Flexão	88%	96%	0%	0%	72%
Supinação	72%	80%	0%	0%	52%
Pronação	100%	96%	96%	96%	88%
Acerto Médio	90%	93%	49%	49%	77%

Tabela 5.21: Grupo de Treinamento - Isométrico - B1T3

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	100%	100%	96%	96%
Flexão	80%	80%	0%	0%	84%
Supinação	80%	56%	12%	0%	60%
Pronação	96%	84%	92%	96%	100%
Acerto Médio	89%	80%	51%	48%	85%

Tabela 5.22: Grupo de Execução - Isométrico - B1T3

As Tabelas 5.23, 5.24, 5.25 e 5.26 apresentam os resultados para a configuração B2T1. Neste caso, a generalização da rede não foi muito afetada pelo tipo de contração realizada. Observe que, para o caso Isométrico - B2T1, uma ordem do modelo AR superior a 6 produz uma queda na capacidade de generalização da rede. Pode-se concluir com isso que a introdução de informações desnecessárias ou redundantes, por exemplo através do aumento da ordem do modelo, influencia na performance do sistema.

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	96%	96%	96%	92%	88%
Flexão	96%	96%	96%	96%	96%
Supinação	100%	100%	96%	96%	84%
Pronação	96%	92%	96%	96%	80%
Acerto Médio	98%	98%	96%	94%	91%

Tabela 5.23: Grupo de Treinamento - Isotônico - B2T1

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	92%	92%	92%	92%	84%
Flexão	96%	100%	100%	96%	84%
Supinação	100%	100%	92%	92%	96%
Pronação	96%	92%	96%	96%	80%
Acerto Médio	96%	96%	95%	94%	86%

Tabela 5.24: Grupo de Execução - Isotônico - B2T1

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	84%	88%	96%	92%	88%
Flexão	100%	100%	96%	96%	96%
Supinação	100%	100%	96%	92%	96%
Pronação	76%	88%	96%	96%	84%
Acerto Médio	90%	94%	96%	94%	91%

Tabela 5.25: Grupo de Treinamento - Isométrico - B2T1

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	88%	80%	92%	96%	84%
Flexão	100%	100%	100%	88%	84%
Supinação	100%	100%	92%	92%	96%
Pronação	76%	80%	96%	92%	80%
Acerto Médio	91%	90%	95%	92%	86%

Tabela 5.26: Grupo de Execução - Isométrico - B2T1

As Tabelas 5.27 a 5.30 e 5.31 a 5.34 apresentam os resultados para a configuração B2T2 e B2T3 respectivamente. Os resultados indicam uma variação na resposta do sistema de classificação em função do tipo de contração realizada. Para contrações isotônicas nota-se uma dificuldade durante a etapa de treinamento e execução. Já para as contrações isométricas, observa-se que o sistema de classificação consegue separar bem as classes de movimentos em análise.

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	76%	92%	80%	72%	92%
Flexão	100%	100%	100%	100%	100%
Supinação	100%	96%	96%	96%	100%
Pronação	76%	64%	72%	52%	64%
Acerto Médio	88%	88%	87%	80%	89%

Tabela 5.27: Grupo de Treinamento - Isotônico - B2T2

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	76%	84%	72%	84%	72%
Flexão	100%	100%	100%	100%	100%
Supinação	100%	92%	96%	100%	96%
Pronação	48%	32%	44%	60%	56%
Acerto Médio	81%	77%	78%	86%	81%

Tabela 5.28: Grupo de Execução - Isotônico - B2T2

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	100%	100%	100%	100%
Flexão	100%	100%	96%	88%	76%
Supinação	96%	100%	100%	88%	88%
Pronação	96%	100%	100%	100%	100%
Acerto Médio	98%	100%	99%	94%	91%

Tabela 5.29: Grupo de Treinamento - Isométrico - B2T2

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	100%	100%	100%	96%
Flexão	100%	96%	92%	88%	76%
Supinação	84%	92%	84%	76%	80%
Pronação	96%	100%	100%	100%	100%
Acerto Médio	95%	97%	94%	91%	88%

Tabela 5.30: Grupo de Execução - Isométrico - B2T2

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	88%	80%	68%	60%	72%
Flexão	100%	100%	100%	100%	100%
Supinação	100%	100%	92%	96%	96%
Pronação	76%	84%	68%	72%	64%
Acerto Médio	91%	91%	82%	82%	83%

Tabela 5.31: Grupo de Treinamento - Isotônico - B2T3

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	60%	60%	44%	64%	44%
Flexão	100%	100%	100%	100%	100%
Supinação	100%	96%	96%	92%	100%
Pronação	52%	84%	76%	64%	40%
Acerto Médio	78%	85%	79%	80%	71%

Tabela 5.32: Grupo de Execução - Isotônico - B2T3

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	100%	100%	28%	96%
Flexão	100%	100%	88%	84%	76%
Supinação	100%	96%	96%	96%	80%
Pronação	100%	96%	92%	100%	88%
Acerto Médio	100%	98%	94%	77%	85%

Tabela 5.33: Grupo de Treinamento - Isométrico - B2T3

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	88%	96%	20%	100%
Flexão	100%	96%	100%	76%	84%
Supinação	100%	92%	76%	100%	88%
Pronação	96%	100%	100%	100%	100%
Acerto Médio	100%	94%	91%	68%	87%

Tabela 5.34: Grupo de Execução - Isométrico - B2T3

De acordo com as análises dos resultados apresentados até o momento, observa-se que para o caso de combinação de pares de eletrodos dois a dois, a que obteve melhor resultado foi B2T1. Visando incrementar a performance desta configuração foi analisada a possibilidade de utilização de mais um par de eletrodo. As combinações analisadas foram: B2T1T2 e B2T1T3. Os resultados obtidos estão apresentados nas Tabelas 5.35 a 5.42.

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	96%	96%	100%	92%	92%
Flexão	100%	100%	100%	100%	100%
Supinação	100%	100%	100%	100%	100%
Pronação	100%	100%	100%	100%	100%
Acerto Médio	99%	99%	99%	98%	98%

Tabela 5.35: Grupo de Treinamento - Isotônico - B2T1T2

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	92%	88%	96%	96%
Flexão	100%	100%	100%	100%	100%
Supinação	100%	96%	100%	92%	100%
Pronação	96%	96%	92%	100%	84%
Acerto Médio	99%	96%	95%	97%	95%

Tabela 5.36: Grupo de Execução - Isotônico - B2T1T2

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	100%	100%	100%	100%
Flexão	100%	100%	100%	96%	88%
Supinação	100%	100%	100%	100%	96%
Pronação	100%	100%	100%	100%	100%
Acerto Médio	100%	100%	100%	99%	95%

Tabela 5.37: Grupo de Treinamento - Isométrico - B2T1T2

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	100%	100%	100%	100%
Flexão	100%	100%	96%	96%	84%
Supinação	96%	100%	100%	100%	44%
Pronação	96%	100%	96%	96%	92%
Acerto Médio	98%	100%	98%	98%	80%

Tabela 5.38: Grupo de Execução - Isométrico - B2T1T2

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	96%	96%	96%	92%
Flexão	100%	100%	100%	100%	100%
Supinação	100%	100%	100%	96%	96%
Pronação	100%	100%	100%	92%	96%
Acerto Médio	100%	99%	99%	96%	96%

Tabela 5.39: Grupo de Treinamento - Isotônico - B2T1T3

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	96%	96%	100%	92%	96%
Flexão	100%	100%	100%	100%	100%
Supinação	96%	88%	92%	96%	96%
Pronação	96%	100%	92%	96%	100%
Acerto Médio	97%	96%	96%	96%	98%

Tabela 5.40: Grupo de Execução - Isotônico - B2T1T3

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	100%	100%	100%	100%
Flexão	100%	100%	96%	96%	80%
Supinação	100%	100%	100%	100%	84%
Pronação	100%	100%	100%	100%	100%
Acerto Médio	100%	100%	99%	99%	91%

Tabela 5.41: Grupo de Treinamento - Isométrico - B2T1T3

Classes de Movimento	Número de Coeficientes				
	10	8	6	4	3
Extensão	100%	100%	100%	100%	100%
Flexão	100%	100%	96%	96%	84%
Supinação	100%	100%	100%	100%	84%
Pronação	92%	100%	92%	92%	96%
Acerto Médio	98%	100%	97%	97%	91%

Tabela 5.42: Grupo de Execução - Isométrico - B2T1T3

Estes resultados mostram que ambas as combinações aumentam a performance do sistema de classificação com relação à combinação B2T1.

5.4 Conclusão

Neste capítulo foram expostas as metodologias experimentais e os resultados obtidos na avaliação do sistema de processamento de sinais EMG desenvolvido. Através dos resultados pode-se concluir que o sistema pode ser utilizado para controlar uma prótese mioelétrica com quatro graus de liberdade, pois foram obtidos resultados satisfatórios para as quatro classes de movimento analisadas. Para tal pode-se utilizar configurações com 5 ou dois pares de eletrodos. No último caso, os sítios que mostraram-se mais indicados para o posicionamento dos eletrodos foram B2 e T1, sendo que o acréscimo de mais um par de eletrodos (T2 ou T3) aumentou a performance do sistema de classificação.

Notou-se ainda que tanto para a configuração de dois pares, quanto para a de cinco pares, um modelo AR de ordem 4 foi suficiente para a extração das características mais importantes do sinal.

Capítulo 6

Conclusão e Trabalhos Futuros

6.1 Conclusões Gerais

Neste trabalho desenvolvemos um sistema de processamento de sinais eletromiográficos capaz de fornecer sinais de controle para uma prótese com quatro graus de liberdade. Para tal, os parâmetros do modelo AR foram utilizados como características representativas do sinal EMG, sendo estas classificadas através de redes neurais.

O modelo AR utilizado mostrou-se capaz de representar o sinal EMG adequadamente, ou seja, seus parâmetros realmente conseguiram associar uma determinada atividade eletromiográfica a um determinado tipo de movimento. As principais vantagens observadas no método são:

- Redução de informações redundantes ou desnecessárias apresentadas ao sistema de classificação (um modelo de quarta ordem mostrou-se suficiente para representar o sinal);
- Eficiência com relação à velocidade e facilidade de cálculos;
- Independência com relação ao deslocamento no tempo ou variações na amplitude do sinal.

Um dos grandes problemas encontrados no modelo AR é com relação ao estabelecimento de sua ordem e da constante de convergência do filtro. O que se observa é que, para

cada sinal, existem uma ordem e uma constante mais adequada, sendo assim, nem sempre os sinais podem ser muito bem representados. Uma consequência imediata disso poderia ser um elevado grau de interpenetração de regiões correspondentes a padrões distintos, tornando-se bastante remota a possibilidade de uma boa separação deste espaço. Foi justamente por isso, que adotou-se a utilização do LMS modificado, sugerido por Veiga *et al.* [40]. Tal algoritmo diminuiu a dependência do processo de cálculo dos parâmetros do modelo AR com relação à constante de convergência do filtro, garantindo assim uma melhor representação do sinal.

Com relação ao sistema de classificação adotado, notou-se que as redes neurais executaram muito bem o papel de segmentação dos coeficientes AR em classes distintas de padrões. Isto pode ser observado através das análises dos resultados obtidos durante a etapa de treinamento. Naquela etapa foram observados alguns problemas inerentes a este classificador:

- Redes demasiadamente treinadas possuem pouca capacidade de generalização, criando superfícies de separação muito especializadas;
- Existe uma certa dificuldade na determinação de valores ideais para os parâmetros de treinamento, tais como: taxa de aprendizagem, momento e quantidade de neurônios utilizados na camada intermediária. Estes parâmetros ainda são escolhidos empiricamente por pesquisadores da área.

A avaliação da etapa de execução do sistema classificador mostrou algumas vantagens dos sistemas neurais em relação a métodos tradicionais, tal como o método Bayesiano. Por exemplo:

- Diminuição do esforço computacional, visto que operações complexas existentes em diversos métodos tradicionais, como inversões de matrizes ou cálculos de matrizes de covariância, são substituídas por operações elementares de soma e subtração;
- Facilidade de análise das variáveis envolvidas no problema, dando a cada uma o peso/influência adequada ao problema. Isto ocorre pois a análise através de redes

CAPÍTULO 6. CONCLUSÃO E TRABALHOS FUTUROS

neurais não exige a necessidade de conhecimento prévio de todas as variáveis envolvidas no problema bem como a influência das mesmas sobre o sistema. Geralmente, isto é feito de maneira automática pela rede;

- Redução da quantidade de informações armazenadas graças a grande capacidade de generalização das redes neurais.

Com relação à realização dos experimentos, pode parecer contraditório ou até mesmo um pouco estranho o fato de se realizar experimentos em um indivíduo normal, num trabalho cujo objetivo principal é a classificação de padrões de sinais no controle de membros artificiais. Porém, tal escolha não invalida o estudo em questão, visto que todas as técnicas de processamento de sinais descritas nos capítulos anteriores podem ser utilizadas para processar sinais EMG em geral, independente de serem provenientes de indivíduos normais ou não.

A proposta de uma metodologia para a realização dos experimentos é um ponto de destaque deste trabalho. O que se observa na literatura em geral, são trabalhos que não seguem metodologia alguma, sendo impossíveis de serem repetidos ou comparados. O projeto da superfície para apoio de eletrodos e o projeto de uma bancada experimental para a realização de contrações isométricas, são exemplos de "ferramentas simples" que podem ser utilizadas para garantir a repetibilidade de experimentos.

Outro objetivo dessa pesquisa foi a busca do número de pares de eletrodos e de sítios mais adequados para a detecção do sinal EMG. Através dos resultados obtidos pode-se observar que cinco pares de eletrodos sobre os sítios B1, B2, T1, T2, T3 e T4 ou dois pares de eletrodos sobre os sítios B2 e T1 podem ser suficientes para uma boa representação da atividade eletromiográfica. Notou-se ainda que o acréscimo de mais um par de eletrodos (sobre o sítio T2 ou T3), na combinação B2T1, pode incrementar os resultados desta combinação. Estas conclusões podem ser observadas através dos resultados apresentados nas Tabelas 6.1 e 6.2. Através da Tabela 6.1 pode-se concluir ainda, que as variações dos resultados para sinais modelados com 4 ou 10 coeficientes AR é mínima.

Contração/Coefficientes	Classes de Movimento				
	Extensão	Flexão	Supinação	Pronação	Média
Isométrico/4	100%	92%	100%	92%	96%
Isométrico/10	100%	100%	100%	100%	100%
Isotônico/4	96%	100%	92%	96%	96%
Isotônico/10	84%	100%	100%	96%	95%

Tabela 6.1: Resultados para 5 pares de eletrodos.

Contração/Sítio	Classes de Movimento				
	Extensão	Flexão	Supinação	Pronação	Média
Isométrico/B2T1	92%	100%	92%	96%	95%
Isotônico/B2T1	96%	96%	96%	96%	96%
Isométrico/B2T1T2	100%	96%	100%	96%	98%
Isotônico/B2T1T2	88%	100%	100%	92%	95%
Isométrico/B2T1T3	100%	100%	100%	92%	98%
Isotônico/B2T1T3	100%	100%	92%	92%	98%

Tabela 6.2: Resultados para combinações de pares de eletrodos e 6 coeficientes AR.

A possibilidade de utilização de um par de eletrodos também foi analisada e um resumo dos resultados obtidos em sua avaliação é mostrado na Tabela 6.3. Esta tabela mostra uma grande dificuldade por parte do sistema em classificar as características dos sinais. Tal fato já era esperado após as análises das superfícies AR apresentadas no Capítulo 5 (Figuras 5.12 a 5.16 e 5.22 a 5.26). Isto pode ter sido em decorrência de:

- Interferências de vários tipos de sinais de músculos ou nervos próximos;
- Baixo ganho do sistema de amplificação;

- Uma baixa razão sinal/ruído do eletromiógrafo para os sinais de baixíssima amplitude captados sobre o plexo braquial.

Contração/Coefficientes	Classes de Movimento				
	Extensão	Flexão	Supinação	Pronação	Média
Isométrico/4	100%	20%	76%	92%	72%
Isométrico/10	96%	48%	80%	64%	72%
Isotônico/4	52%	48%	60%	60%	55%
Isotônico/10	100%	84%	72%	48%	76%

Tabela 6.3: Resultados para 1 par de eletrodos.

No Capítulo 4 destacou-se que este trabalho pode ser considerado como uma extensão e junção de partes dos trabalhos de Hefftner *et al.* (1988) [19] e Gunawardana (1995) [13]. Comparando-se os resultados obtidos com os dos trabalhos mencionados, concluímos que:

- Foram comprovadas as conclusões do trabalho de Hefftner *et al.* (1988) [19], visto que realmente notou-se que o modelamento do sinal EMG, através de métodos AR, é apropriado, pois esse método se mostra confiável para detecção e identificação das diferenças nas características do sinal eletromiográfico, não se limitando a localizações específicas de eletrodos;
- Os índices de acertos obtidos mostram-se superiores aos obtidos por Gunawardana (1995) [13]. Vale lembrar que o mesmo utilizou o sinal EMG para controlar uma prótese com quatro graus de liberdade e obteve índice de acerto de 80% usando redes neurais e 90% usando um classificador bayesiano. Deve-se ainda fazer uma crítica com relação ao trabalho de Gunawardana (1995) [13], pois este em momento algum indicou o número de eletrodos usados ou seu posicionamento, demonstrando uma falta de metodologia para a realização adequada de seus experimentos e nenhuma preocupação com a repetibilidade dos mesmos.

Finalmente, podemos concluir que o modelo proposto para a classificação de sinais EMG executa seu papel com eficiência e pode ser implementado em tempo real. Tal sistema pode ser ainda utilizado como ferramenta de processamento para outros tipos de sinais biomédicos, por exemplo, EEG e ECG.

6.2 Trabalhos Futuros

Observe que, neste trabalho, o sinal EMG foi tratado como um processo fracamente estacionário, visto que seu período de análise foi de 200 ms e o método utilizado na determinação dos parâmetros do modelo AR foi o LMS. Em estudos futuros, poderiam ainda ser feitas análises considerando-o como um processo estacionário, por exemplo através da diminuição do tamanho da janela de análise, ou como um processo não-estacionário, através da determinação das características do sinal pelo filtro de Kalman. Tais estudos poderiam ser comparados com os realizados nesse trabalho e teriam como finalidade verificar se aqueles métodos podem ou não aumentar a separabilidade entre classes de sinais. Não se descarta ainda a possibilidade de utilização de transformadas Wavelets nesse estágio.

Em geral, o que pode ser concluído em relação ao sistema de classificação é que a realização de um bom pré-processamento do sinal pode abrir um leque para a aplicação de classificadores mais simples, como os de distância, tais como os classificadores Euclidianos ou de Malahanobis.

A tentativa de se obter um sistema que consiga realizar um processamento eficiente do sinal, com a utilização de apenas um sítio é realmente excitante. Para isto, estudos futuros podem ser realizados no sentido de aumentar a razão sinal/ruído do eletromiógrafo desenvolvido e de aplicar técnicas de processamento de sinais, para a eliminação de interferências entre sinais de músculos e nervos. Poderiam ainda ser utilizados eletrodos ativos e/ou intramusculares na detecção do sinal, eliminando assim alguns dos grandes problemas da eletromiografia de superfície: ruídos e interferências de sinais de músculos e nervos próximos.

Trabalhos futuros ainda podem ser realizados no sentido de testar todo o sistema desenvolvido em diferentes indivíduos normais e deficientes. Pode ser observada ainda a eficiência do posicionamento adotado para os eletrodos.

Bibliografia

- [1] M. AKAY. *Biomedical Signal Processing*. Academic Press, New Jersey - USA, 1994.
- [2] B. CALAIS-GERMAIN. *Anatomia para o movimento*, volume 1: Introdução à Análise das Técnicas Corporais. Manole LTDA, São Paulo - Brasil, 1991.
- [3] D. S. CHILDRESS. Powered limb prostheses: Their clinical significance. *IEEE Transactions on Biomedical Engineering*, BME-20(3):200-207, Maio 1973.
- [4] J. GRAUPE & K. CLINE. Functional separation of emg signals via arma identification methods for prosthesis control purposes. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-5:252-259, Março 1975.
- [5] R. MERLETTI & L. R. LO CONTE. Advances in processing of surface myoelectric signals: Part 1. *Medical & Biological Eng. & Computing*, 33:362-372, Março 1995.
- [6] R. MERLETTI & L. R. LO CONTE. Advances in processing of surface myoelectric signals: Part 2. *Medical & Biological Eng. & Computing*, 33:373-384, Maio 1995.
- [7] J. KRUIT & J. C. COOL. Body-powered hand prosthesis with low operating power for children. *Journal of Med. Eng. & Tech.*, 13(1/2):129-133, 1989.
- [8] J. D. CRYER. *Time Series Analysis*. Duxbury Press, Boston - USA, 1986.
- [9] G. da C. SOUSA. *Estudo Eletromiográfico da Ação Simultânea de Músculos Flexores e Extensores do Antebraço Pronado e Supinado, em Diferentes Cargas e Ângulos*. PhD thesis, FOP/UNICAMP, 1998.

- [10] L. FAUSETT. *Fundamentals of Neural Networks - Architectures, Algorithms and Applications*. Prentice Hall International, Inc., 1994.
- [11] R. R. GUDWIN. Introdução à semiótica computacional. In *XVII Seminário Nacional dos Estudantes de Engenharia*, Universidade Federal de Goiás, 1996.
- [12] A. GUNAWARDANA. Myoelectric control of a prosthetic hand. www.clsp.jhu/paper.html, Maio 1995.
- [13] A. GUNAWARDANA. Emg extraction and processing. www.fen.bris.ac.uk/elec/research/ccr/medelec/emgext.html, Março 1998.
- [14] A. C. GUYTON. *Basic Neuroscience: Anatomy & Physiology*. W. B. Saunders Company, Philadelphia - PA - USA, second edition, 1991.
- [15] S. HAYKIN. *Neural Networks - A comprehensive Foundation*. Macmillan Publishing Co., New York - USA, 1994.
- [16] L. A. HOFF. Errors in frequency parameters of emg power spectra. *IEEE Transactions on Biomedical Engineering*, 38(11):1077-1088, 1991.
- [17] J. A. DORINGER & N. HOGAN. Performance of above elbow body-powered prostheses in visually guided unconstrained motion tasks. *IEEE Transactions on Biomedical Engineering*, 42(6):621-631, 1995.
- [18] J. R. CRAM & G. S. KASMAN & J. HOLTZ. *Introduction to Surface Electromyography*. Gaithersburg, Maryland, an Aspen Publication, 1998.
- [19] G. HEFFTNER & W. ZUCCHINI & G. G. JAROS. The eletromyogram (emg) as a control signal for functional neuromuscular stimulation - part 1: Autoregressive modeling as a means of emg signature discrimination. *IEEE Transactions on Biomedical Engineering*, 35(34):230-237, Abril 1988.
- [20] E. C. IFEACHOR & B. W. JERVIS. *Digital Signal Processing - A Pratical Approach*. Addison-Wesley, 1993.

- [21] P. E. PATTERSON & J. A. KATZ. Design and evolution of a sensory feedback systems that provides grasping pressure in a myoelectric hand. *Journal of Rehabilitation Research and Development*, 29(1):1-8, 1992.
- [22] R. E. CHALLIS & R. I. KITNEY. The design of digital filters for biomedical signal processing, part 1: Basic concepts. *J. Bioemd. Eng.*, 4:267-278, Outubro 1982.
- [23] R. E. CHALLIS & R. I. KITNEY. Biomedical signal processing, part 2: Time-domain methods. *Medical & Biological Engineering & Computing*, pp:509-524, Novembro 1990.
- [24] D. W. LAMB & H. T. LAW. *Upper-Limb Deficiencies in Children - Prosthetic, Orthotic and Surgical Management*. Little, Brown and Company, Boston, USA, 1987.
- [25] R. P. LIPPMANN. An introduction to computing with neural nets. *IEEE ASSP Magazines*, 4(2):4-22, 1987.
- [26] C. J. D. LUCA. Control of upper-limb prostheses: A case for neuroelectric control. *J. Med. Eng. & Tech.*, 2(2):57-62, 1978.
- [27] C. J. D. LUCA. Physiology and mathematics of myoelectric signals. *IEEE Transactions on Biomedical Engineering*, BME-29(6):313-325, Junho 1979.
- [28] C. J. D. LUCA. Surface electromyography: Detection and recording. www.delsys.com/emg.shtml, Neuromuscular Research Center and Biomedical Engineering Dept. and Neurology Dept., Boston University, Delsys Inc., 1996.
- [29] A. P. BRAGA & A. P. L. F. CARVALHO & T. B. LUDERMIR. Fundamentos de redes neurais artificiais. In *XI Escola de Computação*, Rio de Janeiro, Julho 1998.
- [30] S. K. PAL & D. K. D. MAJUMDER. *Fuzzy - Mathematical Approach to Pattern Recognition*. John Wiley & Sons, Inc., Indian Statistical Institute, Calcutta, India, 1986.

- [31] A. PAPOULIS. *Probability, Random Variables and Stochastic Processes*. McGraw-Hill, 1984.
- [32] R. N. SCOTT & P. A. PARKER. Myoelectric prosthesis: State of the art. *Journal of Med. Eng. & Tech.*, 12(4):143-151, 1988.
- [33] M. Z. PROSDOCIMO. Sistema para transformar texto em voz utilizando redes neurais para a língua portuguesa. Master's thesis, Universidade de São Paulo (USP), 1996.
- [34] T. W. RAUBER. Pattern recognition. In *JAI '97 - XVI Journey of Actualization in Computer Science & XVII Congress of Brazilian Computer Science Society, Short Course*, Brasília, DF, Brasil, 1997.
- [35] REIDMILLER. Proceedings of the ieee int. conf. *IEEE*, pages 586-591, 1993.
- [36] B. HUDGINS & P. PARKER & R. N. SCOTT. A new strategy for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*, 40(1):82-94, 1993.
- [37] P. A. O'NEILL & E. L. MORIN & R. N. SCOTT. Myoelectric signal characteristics from muscles in residual upper limbs. *IEEE Trans. Rehab. Eng.*, 2(4):266-270, 1994.
- [38] U. KURUGANTI & B. HUDGINS & R. N. SCOTT. Two -channel enhancement of a multifunction control system. *IEEE Transactions on Biomedical Engineering*, 42(1):109-111, 1995.
- [39] F. Q. XIONG & E. SHWWDYK. Some aspects of nonstationary myoelectric signal processing. *IEEE Transactions on Biomedical Engineering*, BME-34(2):166-172, Fevereiro 1987.
- [40] A. C. P. VEIGA & A. O. ANDRADE & Y. IANO & A. B. SOARES. Extractions of features from an emg signal for controlling a prosthetic upper limb through an artificial neural network. *ICPR - 2000 - Espanha*, Submetido.

- [41] K. S. TÜRKER. Eletromyography: Some methodological problems and issues. *Physical Therapy*, 73(10):698-710, Outubro 1993.
- [42] S. T. WELSTEAD. *Neural Network and Fuzzy Logic Applications in C/C++*. John Wiley & Sons, Inc., 1994.
- [43] P. C. DOERSCHUK & D. E. GUSTAFSON & A. S. WILLSKY. Upper extremity limb function discrimination using emg signal analysis. *IEEE Transactions on Biomedical Engineering*, BME-30(1):18-29, Janeiro 1983.