



**AUTARQUIA ASSOCIADA À UNIVERSIDADE
DE SÃO PAULO**

**REDES NEURAIIS PARA CONTROLE DE SISTEMAS
DE REATORES NUCLEARES**

BENEDITO DIAS BAPTISTA FILHO

**Tese apresentada como parte dos
requisitos para obtenção do Grau de
Doutor em Ciências na Área de
Tecnologia Nuclear - Reatores.**

**Orientador:
Dr. Adalberto José Soares**

**São Paulo
1998**

INSTITUTO DE PESQUISAS ENERGÉTICAS E NUCLEARES
Autarquia associada à Universidade de São Paulo

**REDES NEURAIS PARA CONTROLE DE SISTEMAS
DE REATORES NUCLEARES**


BENEDITO DIAS BAPTISTA FILHO

**Tese apresentada como parte dos requisitos para
obtenção do grau de Doutor em Ciências na
Área de Tecnologia Nuclear: Reatores.**

**Orientador:
Dr. Adalberto José Soares**

SÃO PAULO

1998



À minha mãe, Ana Maria, à minha esposa, Cecília, e ao meu filho, Ricardo.

AGRADECIMENTOS

Ao colega Dr. Eduardo L. L. Cabral, pela sua valiosa contribuição durante todo o desenvolvimento deste trabalho, destacando sua orientação no desenvolvimento dos modelos de robótica e seus conselhos e sugestões em todos os aspectos do trabalho.

Ao Dr. Adalberto J. Soares, orientador e amigo, pela sugestão do tema, pelo contínuo incentivo e atenção.

REDES NEURAIIS PARA CONTROLE DE SISTEMAS DE REATORES NUCLEARES

Benedito Dias Baptista Filho

RESUMO

Foi desenvolvida uma nova arquitetura de redes neurais artificiais com o objetivo de contribuir para o desenvolvimento de novos sistemas de controle para instalações nucleares e robótica. Os novos conceitos introduzidos com essa arquitetura foram baseados no projeto de redes dedicadas à tarefa, na utilização de múltiplos contatos sinápticos com uma nova função de transferência, e no uso de processos de modificação de forças de ligação sinápticas similares aos de organismos biológicos. Esses conceitos aproveitam os aspectos evolucionários dos sistemas biológicos, tanto na sua arquitetura, quanto nos processos de transmissão de sinais, memória e aprendizado, propiciando uma capacidade de generalização não obtida por meio de redes neurais artificiais clássicas tipo "feed-forward" (F-F).

Os novos conceitos foram aplicados ao controle de um manipulador robótico bi-articulado no plano e ao controle de um sistema termo-hidráulico operando em circulação natural. Sua eficiência e capacidade de generalização foram comparadas com um modelo clássico de redes neurais artificiais tipo F-F, treinada pelo algoritmo de retro-propagação. O excelente desempenho obtido, principalmente no problema do manipulador que caracteriza um sistema de dinâmica mais complexa, demonstrou que a utilização dessa nova rede especializada por tarefa produz resultados muito melhores que os resultados obtidos com a utilização de redes genéricas, como a rede tipo F-F. A tarefa de treinamento da rede proposta foi cerca de 150 vezes mais rápida do que o treinamento da rede tipo F-F com o método de retro-propagação associado à rede tipo F-F. Os resultados mostraram ainda que os erros de posicionamento com o novo modelo foram até 60 vezes menores do que os erros encontrados com a rede tipo F-F.

NEURAL NETWORKS FOR CONTROL OF NUCLEAR REACTORS SYSTEMS

Benedito Dias Baptista Filho

ABSTRACT

A new architecture of artificial neural networks was developed with the objective of contributing with the development of new control systems for nuclear facilities and robotics. The new concepts introduced with this architecture were based in the design of task dedicated networks, in the use of multiple synaptic contacts with new transfer functions, and in the use of synaptic plasticity processes similar to that of biological organisms. These concepts take advantage of the evolutionary aspects of biological systems in their architecture, signal transmission, and memory and learning processes, given rise to a generalization capacity not obtained with classical feed-forward (F-F) neural networks.

The new concepts were applied to the control of a planar two-link robotic manipulator and to the control of a natural circulation water loop. Its efficiency and generalization capacity were compared with a classic neural network in F-F, trained with the back propagation algorithm. The excellent performance obtained, mainly in the manipulator's problem, that characterizes a system of dynamic more complex, demonstrated that the use of the new task specialized network, produces much better results than the results obtained with the use of generic F-F networks. The training task in the new proposed neural network was 150 times faster than the F-F neural network training with back-propagation. The results showed that the positioning errors with the new model were up to 60 times smaller than the errors found with the F-F network.

SUMÁRIO

	Página
1 INTRODUÇÃO	1
1.1 <i>Motivação para o trabalho</i>	1
1.2 <i>Panorama atual e delimitação do assunto</i>	2
1.3 <i>Objetivos da Pesquisa</i>	3
1.4 <i>Organização da Tese</i>	4
2 PRINCIPAIS ASPECTOS DAS REDES NEURAIS ARTIFICIAIS	6
2.1 <i>Aspectos Históricos</i>	6
2.1.1 Neurônio de McCulloch	6
2.1.2 PERCEPTRON	7
2.1.3 ADALINE	8
2.1.4 Aprendizado Competitivo e Retro-Propagação	9
2.2 <i>Arquiteturas de Redes Neurais Artificiais</i>	11
2.3 <i>Principais Algoritmos de Aprendizado</i>	13
2.3.1 Regras de Correção de Erro	14
2.3.2 Regras de Gradiente	15
2.3.3 Algoritmo de Retro-Propagação	17
2.4 <i>Oportunidades de Inovação</i>	21
2.4.1 Funções de Transferência	21
2.4.2 Métodos de Treinamento e Arquitetura	22
2.4.3 Conceituação e Implementação	24
2.4.4 Paradigmas e Proposta de Investigação	24
3 PESQUISA NA NEUROFISIOLOGIA	26
3.1 <i>O Princípio Evolucionário do Processamento Neuronal</i>	27
3.2 <i>Princípios de Organização do Cérebro</i>	28
3.3 <i>Transmissão de Sinais no Cérebro</i>	38
3.3.1 Sinalização	38
3.3.2 Transmissão Sináptica e Potencial Pós-Sináptico	39
3.4 <i>O Aprendizado e os Mecanismos da Memória</i>	44

	3.4.1	Processos de Aprendizado	46
	3.4.2	Mecanismos de Armazenamento de Memória	54
4		DESENVOLVIMENTO DE UM NOVO CONCEITO DE REDES	59
	4.1	<i>Arquitetura e Fluxo de Informações no novo conceito</i>	59
	4.2	<i>Transmissão de Sinais - "Sinalização"</i>	60
	4.3	<i>Aprendizado e Mecanismos de Memória</i>	68
	4.4	<i>Conceito de Unidade de Controle Motor</i>	71
5		MANIPULADOR BI-ARTICULADO NO PLANO	77
	5.1	<i>Modelo da Dinâmica do Manipulador Bi-articulado no Plano</i>	77
	5.2	<i>Acoplamento da Dinâmica do Manipulador com os Controladores</i>	81
	5.3	<i>Solução numérica, Parâmetros e dados do sistema</i>	84
	5.3.1	Solução numérica da dinâmica do manipulador	84
	5.3.2	Implementação dos modelos da rede neural	86
	5.3.3	Parâmetros e Dados Utilizados nos Modelos	90
	5.4	<i>Resultados</i>	91
	5.4.1	Treinamento da Rede	91
	5.4.2	Testes de desempenho da Rede	93
	5.5	<i>Estabilidade do Processo de Treinamento</i>	100
	5.6	<i>Comparação com modelos clássicos de redes neurais artificiais</i>	106
6		BANCADA DE CIRCULAÇÃO NATURAL	118
	6.1	<i>Características do Circuito de Circulação Natural</i>	119
	6.2	<i>Modelo da Dinâmica do Circuito de Circulação Natural</i>	121
	6.2.1	Conservação de Massa e Quantidade de Movimento	122
	6.2.2	Equações de Energia	125
	6.2.3	Modelo para o trocador de calor	127
	6.2.4	Modelo para válvula de regulagem de água de resfriamento	129
	6.3	<i>Acoplamento da Dinâmica da Bancada com uma Rede Neural</i>	130
	6.4	<i>Solução numérica, Parâmetros e dados do sistema</i>	131
	6.4.1	Solução numérica da dinâmica da Bancada	131

6.4.2	Implementação dos modelos da rede neural	139
6.4.3	Dados para simulação	139
6.5	<i>Resultados</i>	148
6.5.1	Treinamento da Rede	148
6.5.2	- Testes de Desempenho	152
7	CONCLUSÕES	159
8	RECOMENDAÇÕES PARA TRABALHOS FUTUROS	162
	APÊNDICE 1 - PROGRAMA DE SIMULAÇÃO DO MANIPULA-	
	DOR BI-ARTICULADO	165
	APÊNDICE 2 - PROGRAMA DE SIMULAÇÃO DA BANCADA DE	
	CIRCULAÇÃO NATURAL	168
	REFERÊNCIAS BIBLIOGRÁFICAS	173

LISTA DE FIGURAS

	Página
Figura 2.1 - “Neurônio” de McCulloch	6
Figura 2.2 - Perceptron de Rosenblatt	8
Figura 2.3 - Discriminador Linear Não Implementa Função "XOR"	8
Figura 2.4 - ADALINE de WIDROW (1960)	9
Figura 2.5 - Tipos de Arquitetura de Redes	12
Figura 2.5 - Classificação de Algoritmos de Aprendizado	15
Figura 2.6 - Processo do “Gradiente Descendente”	16
Figura 2.8 - Rede em “Feed-Forward”	17
Figura 2.9 - Unidade Elementar da Rede	18
Figura 2.10 - Função Sigmóide e Tangente Hiperbólica	18
Figura 2.11 - “Armadilha” dos Mínimos Locais	23
Figura 3.1 - Microestrutura de um circuito nervoso	27
Figura 3.2 - Vista centro-lateral do cérebro humano	29
Figura 3.3 - Grandes regiões do cérebro	29
Figura 3.4 - Principais localizações funcionais	30
Figura 3.5 - Exemplo de circuito divergente	33
Figura 3.6 - Exemplo de circuito convergente	34
Figura 3.7 - Célula Purkinje do Cerebelo	35
Figura 3.8 - Chaveamento por interneurônios	36
Figura 3.9 - Chaveamento por inibição pré-sináptica	36
Figura 3.10 - Exemplo de circuito reverberante	37
Figura 3.11 - Circuito rítmico alternador	37
Figura 3.12 - Sinalização neuronal	38
Figura 3.13 - Esquema simplificado de Sinapse Química de Ach	41
Figura 3.14 - Ampliação de um aglomerado de canais iônicos de Ach	41
Figura 3.15 - Distribuição de pulsos de corrente em uma junção neuromuscular	42
Figura 3.16 - Potencial de ação pós-sináptico	44
Figura 3.17 - Efeito do mecanismo de habituação	49
Figura 3.18 - Circuito neuronal envolvendo a sensitização	50
Figura 3.19 - Mecanismo de Sensitização	50

Figura 3.20 - Mecanismo de Condicionamento	52
Figura 3.21 - Tipos de Conexões Sinápticas	56
Figura 4.1 - Estrutura típica de um circuito de controle	60
Figura 4.2 - Conceito de sinapses múltiplas	62
Figura 4.3 - Exemplo da Função de Transferência Sináptica	63
Figura 4.4 - Aproximação de $S = x$	65
Figura 4.5 - Inflexões indesejáveis	66
Figura 4.6 - Aproximação sem inflexões indesejáveis	67
Figura 4.7 - Circuito Esquemático de “ <i>plastificação sináptica</i> ”	71
Figura 4.8 - Unidade de Controle Motor	74
Figura 5.1 - Representação do Problema do Manipulador Bi-articulado	78
Figura 5.2 - Fator de atrito no mancal combinado	81
Figura 5.3 - Acoplamento de duas unidades de controle motor com o manipulador	83
Figura 5.4 - Esquema do Manipulador Bi-articulado	84
Figura 5.5 - Seqüência de posições comandadas para o treinamento	92
Figura 5.6 - Forças Sinápticas após treinamento	94
Figura 5.7 - Trajetória do manipulador no 1º teste	95
Figura 5.8 - Evolução da distância da extremidade do manipulador ao alvo	96
Figura 5.9 - Evolução do erro angular dos segmentos do manipulador	97
Figura 5.10 - Evolução do torque nos motores	98
Figura 5.11 - Instantâneos da posição do manipulador	99
Figura 5.12 - Evolução da distância ao alvo	99
Figura 5.13 - Controlador para manipulador de uma única articulação	101
Figura 5.14 - Velocidade angular vs. Posição θ para $\theta_D = 0$	105
Figura 5.15 - Esquema Típico de Rede “Feed-Forward” com Retro- Propagação	108
Figura 5.16 - Esquema utilizado com a retro-propagação	109
Figura 5.17 - Evolução do peso $w(jj, l, l)$ na primeira solução obtida	111
Figura 5.18 - Evolução do peso $w(jj, l, l)$	112
Figura 5.19 - Evolução da somatória do erro quadrático	113
Figura 5.20 - Trajetória do manipulador após 4608 rodadas	114

Figura 5.21 - Trajetória do manipulador após 5328 rodadas	115
Figura 5.22 - Evolução da distância da extremidade do manipulador ao alvo	115
Figura 5.23 - Evolução dos erros angulares	116
Figura 5.24 - Comparação das distâncias ao alvo entre o novo modelo e a rede F-F	117
Figura 6.1 - Arranjo do Circuito	120
Figura 6.2 - Fluxograma do Modelo do Circuito de Circulação Natural	122
Figura 6.3 - Discretização para Energia no Fluido	126
Figura 6.4 - Tipos de “nós”	126
Figura 6.5 - Esquema para o Modelo do Trocador de Calor	127
Figura 6.6 - Detalhamento de regiões no Trocador de Calor	128
Figura 6.7 - Modelo para o C_v da válvula	129
Figura 6.8 - Unidade de controle com dois sinais adicionais do sistema sensorio	132
Figura 6.10 - Definição das Regiões modeladas	133
Figura 6.11 - Exemplo de coordenadas	139
Figura 6.12 - Medidas experimentais e balanço térmico no T.C.	143
Figura 6.13 - Diagrama de temperaturas no T.C.	143
Figura 6.14 - Cálculos de $\overline{\Delta T}_{LOG}$ e estimativa do produto \overline{UA} no T.C.	144
Figura 6.15 - Comparação da evolução das temperaturas e vazão calculadas com as medidas no teste de validação	147
Figura 6.16 - Forças de ligação sináptica após 1ª Etapa	150
Figura 6.17 - Forças de ligação sináptica após 2ª Etapa	151
Figura 6.18 - Forças de ligação sináptica após 3ª Etapa	151
Figura 6.19 - Evolução das temperaturas no primário e secundário do T.C.	155
Figura 6.20 - Perturbações relativas	156
Figura 6.21 - Perturbações absolutas e resultados observados	157
Figura 6.22 - Evolução do erro de temperatura absoluto	158
Figura 8.1 - Deslocamento do manipulador para atender trajetória retilínea	164
Figura A1.1 - Caixa de Diálogo do Programa do Manipulador	166
Figura A1.2 - Tela Principal do Programa do Manipulador	167
Figura A2.1 - Tela Principal de acompanhamento do processo	169

Figura A2.2 - Tipos possíveis de interface entre regiões	171
Figura A2.3 - Caixa de Diálogo Inicial	172
Figura A2.4 - Caixa de Diálogo de Condições Gerais	172

LISTA DE TABELAS

	Página
Tabela 5.1 - Características do Manipulador simulado	90
Tabela 5.2 - Características das unidades de controle motor	91
Tabela 5.3 - Forças Sinápticas após treinamento	93
Tabela 6.1 - Definições de nós e interfaces	140
Tabela 6.2 - Dados para Perda de Carga	140
Tabela 6.3 - Dados gerais de posição, áreas e volumes	141
Tabela 6.4 - Coeficientes de transferência de calor assumidos por região do TC	145
Tabela 6.5 - Dados da rede neural	146
Tabela 6.6 - Dados de variação na Temperatura desejada	149
Tabela 6.7 - Dados de variação na Temperatura da água de resfriamento	149
Tabela 6.8 - Dados de variação na abertura da válvula da água de resfriamento	149
Tabela 6.9 - Forças de Ligação Sináptica após treinamento	152
Tabela 6.10 - Dados para apresentação dos testes de desempenho	153

1.1 *Motivação para o trabalho*

A Engenharia Nuclear sempre foi reconhecida como geradora de tecnologia de ponta pelos aspectos inovadores incorporados às plantas nucleares, pelas características de confiabilidade e segurança de todas as instalações nucleares desenvolvidas e pela eterna preocupação dos seus engenheiros em oferecer sistemas de informação e apoio aos operadores visando reduzir as possibilidades de erros de operação.

Essas características avançadas sempre foram desenvolvidas dentro de princípios de segurança que regulamentam o projeto e construção de plantas nucleares de potência, e que na área de controle obrigaram o desenvolvimento de sistemas de controle e de proteção separados física e funcionalmente, com altíssima confiabilidade, e inclusive com diversidade funcional em componentes redundantes.

Paradoxalmente, para se atingir a robustez exigida e assegurar taxas de falha admissíveis, o projeto dos sistemas de proteção de plantas nucleares considera o uso de até quatro canais redundantes, além de utilizar somente a tecnologia comprovada dos sistemas analógicos, que certamente apresentam inúmeras limitações em relação à tecnologia digital, ou seja, até o presente a engenharia nuclear está defasada em relação a outras aplicações em grande parte de seus sistemas de controle pois a adequação de sistemas de proteção baseados em computador ainda não é comprovada (Hunns e Wainwright, 1991).

Os métodos clássicos de controle utilizados têm dificuldade em lidar simultaneamente com essas questões de segurança, de confiabilidade e com sistemas de dinâmica

muito complexa. Quando os processos são muito complexos, é necessário um grande esforço experimental e/ou computacional para o desenvolvimento dos sistemas de controle, e mesmo assim, quando as incertezas são grandes, não se pode assegurar a princípio que o controle clássico irá oferecer a robustez necessária.

O desenvolvimento de sistemas de controle tais que uma falha simples não cause riscos às funções de proteção irá permitir a concentração dos esforços da engenharia nas áreas onde o desempenho é o mais importante, levando ao desenvolvimento de instalações além de seguras, de muito menor custo.

1.2 *Panorama atual e delimitação do assunto*

Há muito tempo o homem observa que sistemas de controle biológicos são extremamente bem sucedidos no tratamento de problemas complexos de controle. Dentro desse contexto foram desenvolvidos os conceitos de *controle adaptativo* que inclui o campo de *redes neurais artificiais*.

Para aplicações de controle, a vantagem de um controlador baseado em redes neurais é decorrente dos seguintes aspectos: a) em princípio não é necessário o conhecimento teórico do processo que será controlado; b) a grande robustez dos sistemas biológicos que, devido ao seu paralelismo, podem manter um bom desempenho mesmo quando sujeitos a danos e até mesmo a perda de parte de seus componentes; e, c) a rapidez de resposta devido à sua simplicidade e também devido ao seu grande paralelismo. Por outro lado ainda há muito que fazer no sentido de se obter a qualificação de sistemas baseados em redes neurais ou inteligência artificial, mesmo porque sua implementação, até o momento, é feita utilizando-se sistemas digitais, cuja qualificação ainda é um problema sem solução.

As redes neurais artificiais são baseadas na idéia de se imitar o cérebro humano utilizando modelos simplificados das unidades de processamento, representando os neurônios, associadas em grande quantidade e organizadas em paralelo e em camadas.

Entretanto, a implementação dessa idéia nas redes neurais artificiais, tem mostrado limitada capacidade de aprendizado e adaptação, não propiciando generalização e demandando excessivo esforço. Isso ocorre em muito devido o domínio de redes que utilizam algoritmos de treinamento supervisionado. Sabendo que, a menos dessas limitações, as redes neurais artificiais oferecem possibilidades inusitadas em termos de eficiência e robustez, é essencial a solução dos aspectos de treinamento e generalização para ser possível sua utilização em futuros sistemas de controle de centrais nucleares.

1.3 *Objetivos da Pesquisa*

O objetivo do trabalho é o desenvolvimento de um novo conceito de redes neurais artificiais para controle de sistemas dinâmicos com base nos mais recentes conhecimentos da neurofisiologia. A ênfase na neurofisiologia objetiva aproveitar, da maneira mais efetiva possível, o aspecto evolucionário dos sistemas biológicos, reduzindo os aspectos limitantes de treinamento supervisionado das redes neurais artificiais atualmente utilizadas em controle.

O conceito desenvolvido deverá ter aplicação comprovada em sistemas não-lineares e de alta complexidade dinâmica, para isso serão consideradas duas aplicações:

- controle de um manipulador robótico bi-articulado no plano; e,
- controle de um sistema termo-hidráulico não-linear.

O controle de manipuladores tem aplicação na robótica, independentemente do tipo de manipulador, e se destaca pela extrema complexidade dinâmica e alta não-linearidade. O controle de sistemas de reatores apresenta um grande desafio por se tratar de um processo não-linear que pode também demonstrar a capacidade de previsão e de generalização do sistema desenvolvido.

Para comprovar o novo conceito de redes neurais artificiais serão desenvolvidos modelos numéricos dos processos propostos, tanto do manipulador robótico quanto do processo termo-hidráulico e as redes serão simuladas digitalmente, sendo o trabalho concluído com base nesses modelos.

1.4 *Organização da Tese*

Neste Capítulo é apresentada esta introdução que situa o tema da tese e define os objetivos do trabalho. No Capítulo 2 são abordados os principais aspectos teóricos dos atuais conceitos considerados nas redes neurais artificiais e são abordadas as áreas com oportunidade de inovação. No Capítulo 3 é resumida a pesquisa realizada no campo da neurofisiologia, relacionando-a com os aspectos congruentes e com os aspectos divergentes em relação às redes neurais artificiais. No Capítulo 4 é desenvolvido o conceito inovador de rede neural artificial na forma de “unidades de controle motor”. No Capítulo 5 é desenvolvido o modelo para simulação da dinâmica de um manipulador robótico bi-articulado no plano e sua associação com unidades de controle motor. São apresentados os modelos e detalhados os métodos de solução numérica empregados. É apresentada uma avaliação de desempenho da rede e do processo de treinamento por meio de simulações de comandos de posicionamento. A eficiência e capacidade de generalização do novo conceito é comparada com um modelo clássico de redes neurais artificiais tipo “*feed-forward*” com o algoritmo

de retro-propagação. Ainda nesse capítulo, é apresentada uma análise sobre a estabilidade do novo controlador neural no problema do manipulador bi-articulado no plano. No Capítulo 6 são apresentados o modelo e os resultados da simulação e controle de uma bancada experimental que reproduz um sistema de resfriamento de emergência típico de um Reator PWR avançado e, também, empregado em aplicações navais. O modelo da rede neural para controle de potência do aquecedor dessa bancada foi elaborado a partir dos conceitos desenvolvidos no Capítulo 4 adicionados a novos artifícios que ilustram como tornar o modelo mais versátil. O Capítulo 7 contém um sumário das principais conclusões e, finalmente, o Capítulo 8 contém algumas recomendações para prosseguimento da pesquisa com novos trabalhos.

2 PRINCIPAIS ASPECTOS DAS REDES NEURAIS ARTIFICIAIS

2.1 Aspectos Históricos

Apesar de relativamente recente, o desenvolvimento no campo das redes neurais artificiais, objeto do estudo de pesquisadores das mais diferentes áreas, está presente em vasta literatura voltada para as mais variadas aplicações. Para os objetivos deste trabalho serão apenas referidos alguns dos desenvolvimentos mais conhecidos que poderão auxiliar na avaliação da nova abordagem desenvolvida, principalmente nos aspectos conceituais.

2.1.1 Neurônio de McCulloch

Inspirada na neurociência, a teoria de redes neurais artificiais tem evoluído principalmente com base na investigação feita por matemáticos, físicos e engenheiros. No início da década de quarenta, o neurofisiologista Warren McCulloch e o matemático Walter Pitts (1943) propuseram, como modelo de um neurônio, a unidade binária ilustrada na Figura 2.1.




Figura 2.1 - "Neurônio" de McCulloch.

Apesar do grande interesse despertado e da boa vontade dos pesquisadores da época, o desenvolvimento da teoria de redes neurais foi muito difícil no seu início. As

primeiras dificuldades surgiram com a falta de máquinas adequadas e robustas o suficiente para implementação de modelos. Só na metade da década de cinquenta John von Neumann (1956) iniciou a solução do problema de se construir máquinas confiáveis com componentes não confiáveis introduzindo o conceito de *redundância* e originando a geração dos atuais computadores digitais.

A partir do modelo de neurônio de McCulloch, com o avanço da eletrônica, as pesquisas para desenvolvimento de um computador baseado em redes neurais evoluíram passando por períodos de entusiasmo, crítica e descrença, e novamente de entusiasmo.

2.1.2 PERCEPTRON

Rosenblatt (1958) apresentou o projeto de um computador neural denominado PERCEPTRON, esquematizado na Figura 2.2. O PERCEPTRON original possuía 400 células fotoelétricas, recebendo estímulos óticos primários e interligadas a elementos processadores que, dependendo da entrada, produziam uma resposta.

De 1960 a 1962 o grupo de Rosenblatt se concentrou no problema do treinamento do PERCEPTRON, tendo conseguido provar a convergência de um algoritmo de aprendizado. Apesar dos resultados com os experimentos iniciais terem sido muito promissores, esbarraram na limitação de que a única camada de discriminadores lineares do PERCEPTRON não era capaz de implementar todas as possíveis funções “Boleanas”, como o “ou-exclusivo” ilustrado na Figura 2.3. Esse problema devia-se à inabilidade do algoritmo de aprendizado de resolver o problema da atribuição de crédito, ou seja, de que todos os elementos são responsáveis pela resposta certa ou errada. Hoje sabe-se que grupos de elementos simples organizados em camadas, semelhantes aos PERCEPTRONS mas utilizando a *regra delta* de aprendizado, aplicável a unidades com função de transferência linear, com

δ representando o erro (*saída desejada – saída atual*), podem implementar todas as funções básicas dos computadores digitais (Hertz, Krogh, e Palmer, 1991).

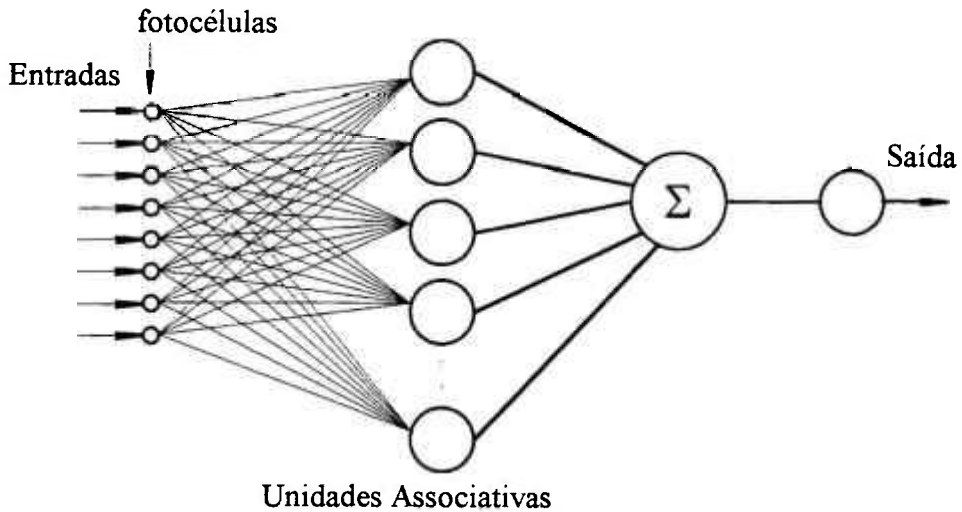


Figura 2.2 - Perceptron de Rosenblatt.




Figura 2.3 - Discriminador Linear Não Implementa Função "XOR".

2.1.3 ADALINE

Widrow e Hoff (1960) seguiram por um caminho diferente de Rosenblatt e introduziram o conceito batizado de ADALINE (sigla de ADaptive LInear Element), representado na Figura 2.4. A composição de uma rede com múltiplos ADALINES's dá origem ao MADALINE, que será mencionado mais adiante quando os aspectos de arquitetura e de algoritmos de aprendizado forem tratados.

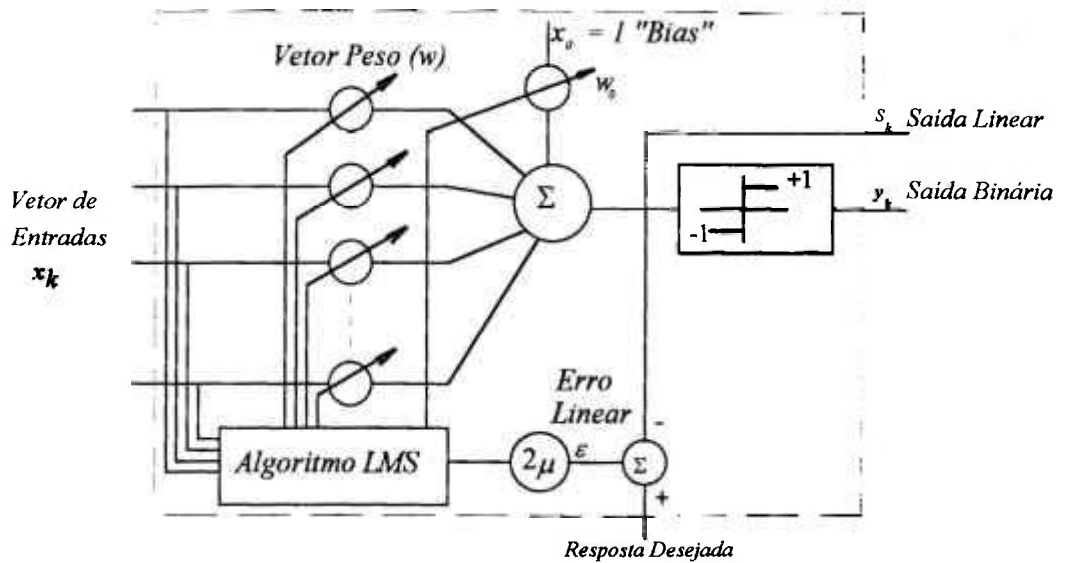


Figura 2.4 - ADALINE de WIDROW (1960).

Hertz, Krogh e Palmer (1991) associam ao ADALINE, juntamente com o PERCEPTRON, as duas contribuições que deram início a um grande ciclo de entusiasmo, que no entanto esbarrou na dificuldade da *separação linear* e no problema de implementação de todas as funções possíveis. Como quase até o final da década de sessenta não se vislumbrou uma solução adequada para esse problema, culminando ainda com a publicação de uma profunda análise crítica elaborada por Minsky e Papert (1969) no seu livro intitulado PERCEPTRONS, foram praticamente cortados todos os recursos destinados às pesquisas em redes neurais.

2.1.4 Aprendizagem Competitivo e Retro-Propagação

Apesar do arrefecimento provocado pelo corte dos investimentos em redes neurais, ainda com muita dificuldade, alguns pesquisadores continuaram seu trabalho, como James Anderson (1968), que trabalhava em um modelo baseado em modelos biológicos da memória e de reconhecimento, nos quais as forças de ligação sinápticas são fortalecidas quanto mais frequentemente são ativadas. Também prosseguiram os trabalhos de Teuvo

Kohonen (1974-1982) que desenvolveu o conceito de uma rede chamada “*mapa auto-organizável*”. A contribuição de Kohonen define o conceito de “aprendizado competitivo”, no qual as unidades competem para responder a determinada entrada e o elemento vencedor tem os pesos de suas entradas modificado para responder a valores próximos dessa entrada cada vez com maior força.

Stephen Grossberg (1967-1969) também prosseguiu seus estudos procurando utilizar dados neurológicos na construção de novos modelos em computação neural. Seus trabalhos se focalizaram no estudo dos reflexos condicionados, baseando-se nos postulados de Hebb (1949) sobre o aprendizado, que será discutido mais adiante.

Também alheio à crença de inviabilidade, Werbos (1974) desenvolveu e apresentou na sua tese de doutorado um algoritmo de aprendizado que é o método atualmente denominado de “retro-propagação”. Infelizmente esse algoritmo não chegou a ser disseminado na época.

Esse mesmo algoritmo foi reinventado por Parker (1982), também ainda sem uma merecida divulgação. Ainda em 1982 John Hopfield (1982) apresentou um trabalho que é uma particularização do trabalho de Grossberg e que ficou conhecido como “redes associativas em linha transversal”, constituídas por elementos interligados buscando o aprendizado com “um mínimo de energia”. O trabalho de Hopfield originou um novo ciclo de entusiasmo e progresso na área.

Em 1985, Rumelhart, Hinton e Williams (1985) mais uma vez reinventaram o algoritmo de retro-propagação e, somente a partir daí, se passou a desenvolver muitas pesquisas dentro dessa linha. Atualmente muitos grupos, em praticamente todas as universida-

des e centros de pesquisa, desenvolvem trabalhos no campo de redes neurais artificiais baseados nos estudos acima.

Posteriormente alguns dos tópicos expostos neste item serão mencionados novamente, buscando apenas uma organização das idéias em termos de classificações por estrutura e por algoritmo de aprendizado.


2.2 *Arquiteturas de Redes Neurais Artificiais*

De um modo geral as redes neurais artificiais são formadas por arranjos regulares de unidades que representam os neurônios. Essas unidades são uniformemente organizadas e associadas em paralelo e em camadas, como se constituíssem o cérebro no seu mais primitivo estágio de desenvolvimento, ou seja, antes de adquirir “*significado*”. As *forças de ligação* entre essas unidades, usualmente denominadas de “*pesos*”, são ajustadas durante um processo de aprendizado.


A exemplo do neurônio de McCulloch (Figura 2.1), a transmissão dos sinais entre as unidades se resume em: amplificação ou atenuação linear dos sinais de entrada, através da sua multiplicação pelos pesos; soma desses sinais ponderados; e, emissão de um sinal de resposta filtrado por meio de uma função de transferência que em geral é uma tangente hiperbólica ou uma sigmóide.

Com base nesses conceitos é que se define a *arquitetura da rede*: que é o modo de organização de suas unidades em conjunto com o fluxo de sinais e ainda, às vezes, em conjunto com o processo de aprendizado envolvido.

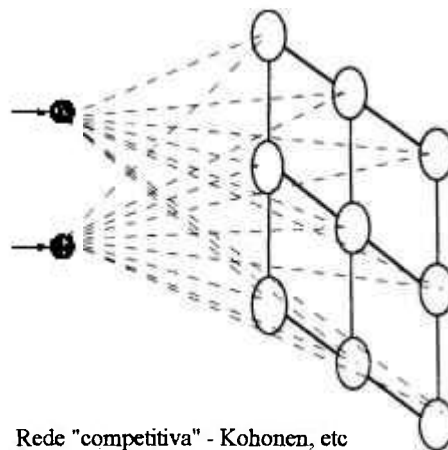
A Figura 2.5 apresenta três das arquiteturas de rede mais conhecidas: as *redes em "feed-forward"*; as *redes em "feedback"*; e as *redes competitivas*.



Rede em "feed-forward" - Retro-Propagação, MADALINE, etc



Rede em "feedback" - Hopfield, Boltzmann, etc.



Rede "competitiva" - Kohonen, etc

Figura 2.5 - Tipos de Arquitetura de Redes.

Com cada tipo de arquitetura existem as mais diversas aplicações, como por exemplo: *reconhecimento de padrões* por meio de PERCEPTRONS; *previsão do tempo* utilizando

MADALINE; *codificação e compressão de imagens*, etc., todas essas utilizando redes em “feed-forward”. Com outras arquiteturas pode ser citado o *controle de posição de um braço robótico* utilizando a rede competitiva de Kohonen; formação de *memória associativa* utilizando redes em “feedback” de Hopfield, etc.

Muitos outros conceitos, que até poderiam ser encaixados nos tipos de arquitetura descritos anteriormente, são tratados como se fossem uma arquitetura diferente por introduzirem significativos aperfeiçoamentos, nesse caso são batizados conforme sua aplicação ou pelo nome de seu idealizador.

É evidente que o assunto “*arquitetura de redes*” é vasto e poderia ser bem mais estendido, no entanto, para o propósito deste trabalho, o essencial está na apresentação dos conceitos de organização das unidades e a ilustração de sua classificação.

Um maior aprofundamento apenas se faz necessário ainda no que se refere aos processos de treinamento, os conhecidos “algoritmos de aprendizado”, que serão vistos a seguir.

2.3 Principais Algoritmos de Aprendizado

Aprendizado é o processo de adaptação das forças de ligação (pesos), em resposta aos estímulos introduzidos na entrada da rede, de modo a produzir o resultado desejado na sua saída. Quando o resultado de saída é conhecido em termos de valor, diz-se que o aprendizado é “supervisionado”. Quando se sabe apenas qualitativamente se a saída é boa ou não, diz-se que o aprendizado é “por reforço”. Porém, qualquer que seja o tipo de aprendizado, ele é obtido através de processos de treinamento cuja implementação e eficácia irão depender do algoritmo empregado para adaptação dos pesos.

Os principais algoritmos de aprendizado empregados em geral são classificados em duas grandes categorias, que refletem o tipo de regra básica empregada:

- a) *Regras de Correção de Erro*: onde a atualização dos pesos é função direta do erro nas saídas; e,
- b) *Regras de Gradiente Descendente*: onde a atualização segue o gradiente negativo de uma função custo para os pesos.

A Figura 2.5 ilustra a classificação dos algoritmos mais conhecidos dentro dessa idéia.

2.3.1 *Regras de Correção de Erro*

Na sua essência todos os algoritmos guardam uma origem comum na idéia de Hebb (1949), um psicólogo que postulou que as sinapses do sistema nervoso se adaptam proporcionalmente à atividade dos neurônios pré- e pós-sinápticos. Desse postulado se desenvolveu um algoritmo para correção dos pesos w :

$$\Delta w_{i,m} = \eta \varepsilon_m x_{i,m} \quad (2.1)$$

onde: $\Delta w_{i,m}$ é o incremento ao peso de ligação da sinapse i do neurônio m ; ε_m é a diferença entre o valor de saída desejado no neurônio m e o valor atual de saída ($y_{Dm} - y_m$); $x_{i,m}$ é o sinal de entrada através da sinapse i do neurônio m ; e, η é um parâmetro batizado de *taxa de aprendizado*.

Esse conceito representa precisamente a *Regra de Correção de Erro*, que pode ser utilizada através de dois processos: após a exibição de cada exemplo, *método passo-a-passo*; ou, após a exibição de todo o conjunto de dados, *método da batelada*.

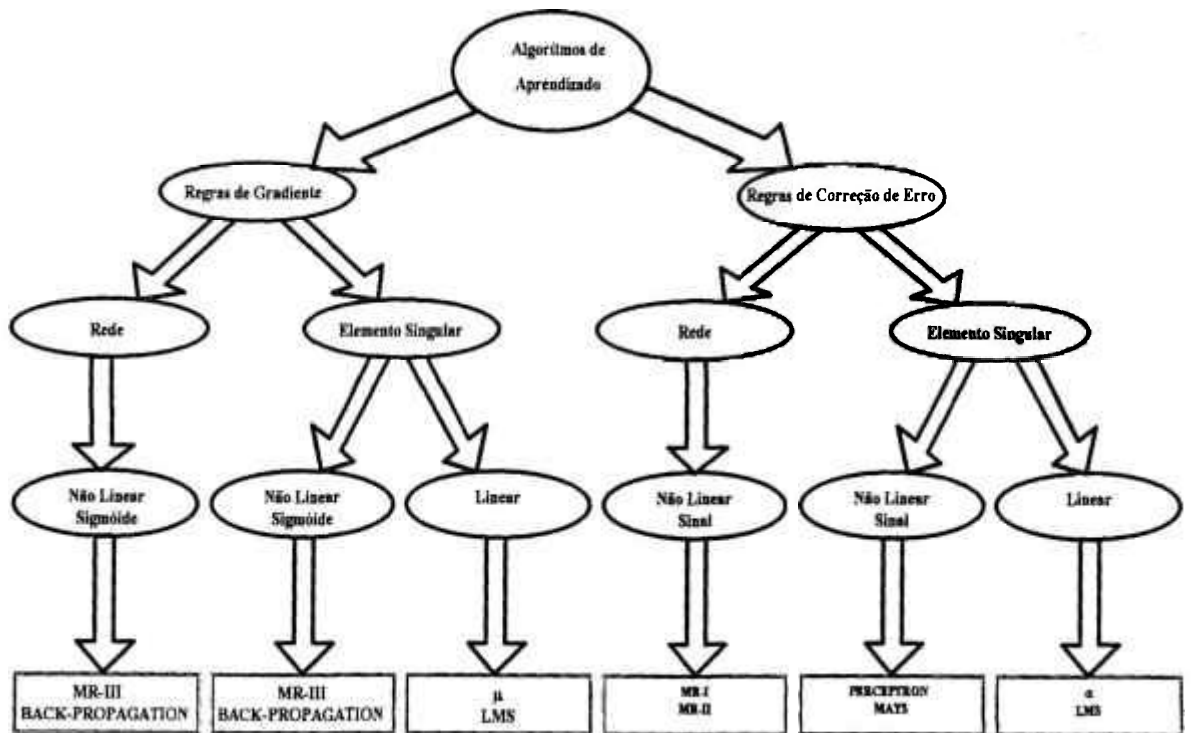


Figura 2.5 - Classificação de Algoritmos de Aprendizagem (Widrow e Lehr, 1990).

2.3.2 Regras de Gradiente

Por outro lado existem as Regras de Gradiente que consideram uma Função Energia, $E(w)$ e buscam sua minimização por meio do método do *minimo erro médio quadrático*. Para esta categoria são necessárias funções de transferência diferenciáveis. As regras de gradiente se baseiam nas definições abaixo, com as convenções dadas após o conjunto de equações:

$$\varepsilon^p = (Y^p - Y^{d,p})^2 \quad (2.2)$$

$$E(w) = \frac{1}{2} \sum_{p=1}^P \varepsilon^p = \frac{1}{2} \sum_{p=1}^P (Y^p - Y^{d,p})^2 = \frac{1}{2} \sum_{p=1}^P [Y^p - g(w^T x^p)]^2 \quad (2.3)$$

$$\Delta w = -\eta \frac{\partial E(w)}{\partial w} \quad (2.4)$$

$$\frac{\partial E(w)}{\partial w} = \frac{\partial E(w)}{\partial Y} \frac{\partial Y}{\partial w} \quad (2.5)$$

onde, \mathcal{E} representa o erro quadrático, que é o quadrado da diferença entre a saída, Y atual e a saída Y desejada; os sobrescritos p e d se referem respectivamente ao padrão p apresentado na entrada (exemplo) e ao valor y desejado na saída; $g(\cdot)$ é a função de transferência da unidade, que é uma função diferenciável; η é a *taxa de aprendizado*; $E(w)$ representa a definição da função energia; e Δw é o incremento de correção do peso sináptico.

O processo que se desenvolve por esse método segue o percurso que conduz ao mínimo da função E , como ilustra a Figura 2.6.




Figura 2.6 - Processo do “Gradiente Descendente”.

Os algoritmos de aprendizado que utilizam regras de gradiente se destacaram principalmente em função do sucesso dos algoritmos MR-III (MADALINE Rule III) e BACK-PROPAGATION (retro-propagação). Como o algoritmo de retro-propagação será

utilizado para comparação, sua apresentação será realizada com mais profundidade neste capítulo.

2.3.3 Algoritmo de Retro-Propagação

O método de retro-propagação tem sido considerado a melhor opção em treinamento para aplicações de controle [Chen (1990)]. A Figura 2.8 mostra uma rede tipo “feed-forward” preparada para ilustrar a modelagem desse método.

Cada unidade ilustrada na Figura 2.8 corresponde a um elemento processador como o esquematizado na Figura 2.9, que representa o *i-ésimo* elemento da camada *j*, já seguindo uma notação adequada para implementação numérica em um programa de computador:




Figura 2.8 - Rede em “Feed-Forward”.




Figura 2.9 - Unidade Elementar da Rede.

Para a função de transferência, $g(v)$, são utilizadas ou a função sigmóide ou a $\tanh(v)$ apresentadas na Figura 2.10.




Figura 2.10 - Função Sigmóide e Tangente Hiperbólica.

A implementação numérica do método por meio de um programa digital segue os passos apresentados a seguir. Dado um vetor x de entradas para a rede da Figura 2.8, é necessária a escolha inicial dos pesos. A obtenção de uma solução vai depender des-

ses pesos iniciais, que devem ser gerados de forma aleatória e com valores iniciais pequenos em função do número total de unidades, de modo a não produzir uma situação inicial de saturação da rede, que ficaria “*paralisada*” logo no início. A partir desse instante é realizada a *propagação para frente*, da primeira à última camada, ou seja, são calculados os valores de saída y 's, partindo da entrada até a saída, por meio das seguintes relações:

para a primeira camada ($j = 1; i = 1 \rightarrow iij_1$):

$$v_{1,i} = \sum_{k=1}^{iie} (w_{1,i,k} x_k) - w_{0,1,i} \quad (2.6)$$

$$y_{1,i} = \tanh(\beta v_{1,i}) \quad (2.7)$$

para as demais camadas ($j = 2, jj; i = 1 \rightarrow iij_j$):

$$v_{j,i} = \sum_{k=1}^{iij(j-1)} (w_{j,i,k} y_{j-1,k}) - w_{0,j,i} \quad (2.8)$$

$$y_{j,i} = \tanh(\beta v_{j,i}) \quad (2.9)$$

Para desenvolver o processo de aprendizado, o algoritmo de retropropagação requer que estejam disponíveis os valores de saída desejados (yd_i^p) para cada padrão (p) de entrada x , para a determinação do erro. À relação de dados constituída pelo conjunto de *entradas/saídas desejadas* é dado o nome de “*Tabela de Treinamento*”. Para a obtenção do primeiro valor de y são utilizados os pesos iniciais, gerados aleatoriamente. Em seguida é executado o processo de avanço (*forward*). A partir desse ponto, considera-se a definição da *Função Energia* dada na Equação 2.3 e reescrita conforme a notação escolhida

para a programação, e aplica-se as demais definições dos métodos de gradiente à camada de saída, obtendo-se o incremento dos pesos, Δw :

$$E(w) = \frac{1}{2} \sum_i [y d_i - y_{j,i}]^2 - \frac{1}{2} \sum_i [y d_i - g(v_{j,i})]^2 \quad (2.10)$$

$$g(v_{j,i}) = g\left(\sum_k w_{j,i,k} \cdot y_{j-1,k} - w_{0,j,i}\right) \quad (2.11)$$

$$\Delta w_{j,i,k} = -\eta \frac{\partial E}{\partial w_{j,i,k}} = \eta \sum_i [y d_i - y_{j,i}] g'(v_{j,i}) y_{j-1,i} \quad (2.12)$$

onde $g(v)$ é a *função de transferência* da unidade e $g'(v)$ é a *derivada dessa função*.

Definindo-se δ como:

$$\delta_{j,i} = g'(v_i)[y d_i - y_{j,i}] \quad (2.13)$$

e considerando-se a tangente hiperbólica como função de transferência:

$$g(v) = \tanh(\beta v), \quad (2.14)$$

tem-se:

$$g'(v) = \beta [1 - g^2(v)] \quad (2.15)$$

$$\delta_{j,i} = \beta [1 - y_{j,i}^2] [y d_i - y_{j,i}] \quad (2.16)$$

Essa definição de δ , iniciada pela última camada, pode ser propagada para trás até a primeira camada (de $j = 1 \rightarrow jj - 1$ e $i = 1 \rightarrow iij_j$):

$$\delta_{j,i} = \beta [1 - y_{j,i}^2] \left[\sum_{k=1}^{i\#(j+1)} w_{j+1,k,i} \delta_{j+1,k} \right] \quad (2.17)$$

e, por conseguinte:

$$\Delta w_{j,i,k} = \eta \delta_{j,i} y_{j-1,k} \quad \text{para } k = 1 \rightarrow i\#j \quad (2.18)$$

$$\Delta w_{0,j,i} = -\eta \delta_{j,i} \quad (2.19)$$

Como a obtenção de uma solução adequada pode não ser imediata, pois depende da escolha dos parâmetros η e β , esse processo pode ter que ser repetido integralmente várias vezes. Porém, como a função de energia pode possuir pontos de *mínimos locais*, não é assegurado que seja atingida uma solução adequada, e portanto a sua implementação requer a inclusão de dois limitadores para o processo de aprendizado, o número máximo de rodadas de apresentação dos exemplos (m) e, uma tolerância para o máximo erro admissível. Atingida a tolerância especificada encerra-se a *fase de treinamento*, iniciando-se a *fase de ação*, quando a estrutura que realiza a retro-propagação pode ser eliminada e a rede pode ser utilizada somente para realizar previsões.

2.4 Oportunidades de Inovação

2.4.1 Funções de Transferência

Devido principalmente a limitações computacionais, a simplificação tem sido a ênfase na escolha das funções de transferência nas redes neurais artificiais. Apesar de se considerar fundamental a não-linearidade nas *funções de transferência*, também conhecidas como *funções de ganho* ou de *ativação*, a necessidade de simplificação tem conduzido à manutenção das tradicionais funções sigmóide e tangente hiperbólica. Hertz, Krogh e Palmer (1991) mostram ainda que não é usual também a consideração de atualização assíncro-

na, diferenças de fase, etc. Dessa forma, pode ser feito algum esforço para inovar em termos de funções de transferência.

2.4.2 *Métodos de Treinamento e Arquitetura*

Existem diversas oportunidades de inovação em termos de métodos de treinamento de redes neurais. Com esse objetivo, logo no início dos estudos para o desenvolvimento desta tese, foi implementado o método de retro-propagação por meio de um programa escrito em FORTRAN. Diversos testes, considerando aproximação de funções e emulação de funções Booleanas, foram realizados para investigar as seguintes limitações:

- a) a convergência depende dos valores iniciais atribuídos aos pesos;
- b) a convergência depende ainda do “passo”, ou seja, da *taxa de aprendizado*;
- c) em problemas com alta não-linearidade existe o risco de ser atingido algum mínimo local, impossibilitando a continuidade da solução conforme ilustrado na Figura 2.11. Nesse caso a convergência não é atingida com 100% de certeza; e,
- d) de um modo geral (como será discutido no Capítulo 6), as aplicações para controle requerem a modelagem de duas redes, uma para o processo e outra para o controle além de requerer em muitos casos, um controlador externo para gerar os valores desejados de saída para treinamento da rede de processo.

Os resultados de fato confirmaram esses aspectos. Além disso, diversos trabalhos publicados nos últimos anos apontam limitações no algoritmo de retro-propagação, mostrando novas oportunidades para inovação. O estudo de Kolen e Goel (1991), apresenta uma amostragem das principais questões. Nesse estudo, os autores relatam os resultados de uma série de experimentos nos quais buscaram identificar as limitações desse algoritmo. Apesar de muito pessimistas, principalmente por não levarem em conta os méritos do método, suas conclusões foram que:

- (1) a eficiência do aprendizado depende dos ganhos iniciais da rede;
- (2) o conteúdo e a quantidade de informações aprendidas depende da configuração inicial da rede (número de camadas e de unidades); e
- (3) o trabalho de aprendizado das redes neurais é extremamente demandante em termos computacionais, dependendo do porte do problema podem ser despendidas horas e até mesmo dias de processamento para então se concluir que toda a estrutura da rede deve ser alterada.

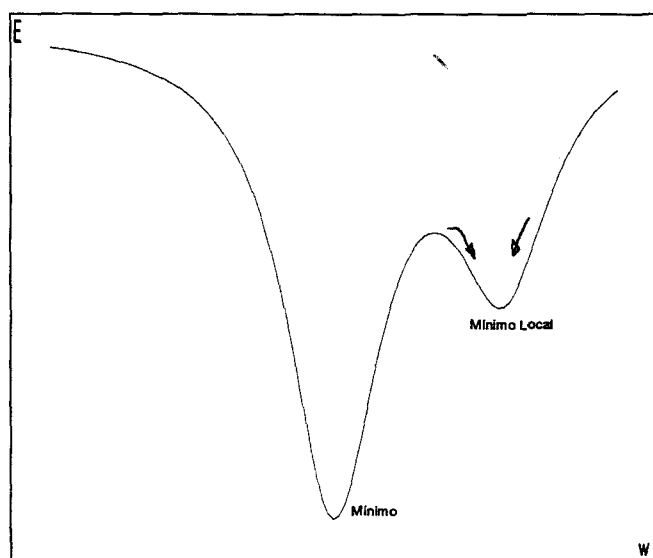


Figura 2.11 - “Armadilha” dos Mínimos Locais.

Os resultados de Kolen e Goel indicaram ainda que os métodos de treinamento atuais são em geral muito limitados para o porte dos problemas que eles pretendem tratar. Com isso eles propõem que o potencial de aplicação das redes neurais possa ser ampliado pelo desenvolvimento de redes específicas, dedicadas para cada tipo de tarefa. Propõem ainda que um sistema capaz de aprender de maneira eficiente deva ter as seguintes habilidades:

- 1 - ser capaz de representar o que conhece e o que deve ser aprendido;
- 2 - ser capaz de identificar seus componentes causadores de erros;

- 3 - *ser capaz de modificar sua estrutura de modo a realizar corretamente seu trabalho;*
- 4 - *ser capaz de generalizar o que é aprendido; e,*
- 5 - *ser computacionalmente eficiente.*

2.4.3 *Conceituação e Implementação*

Em relação às demais especificidades das redes neurais, é possível encontrar grandes oportunidades de inovação na proposta de Hertz, Krogh e Palmer (1991), quanto a questões que devem ser esclarecidas para a implementação satisfatória de qualquer rede neural:

- a) *qual é a melhor arquitetura de uma rede?*
- b) *qual deve ser o número de conexões e como as redes devem ser organizadas?*
- c) *que tipo de função de transferência deve ser utilizada?*
- d) *que forma de atualização de ganhos deve ser utilizada?*
- e) *quantos neurônios devem ser utilizados?*
- f) *a rede pode aprender em tempo real durante o funcionamento ou, a etapa de treinamento deve ser realizada antes da sua utilização?*
- g) *o que cada tipo de rede neural é capaz de realizar?*
- h) *quantas informações diferentes uma rede pode aprender?*
- i) *qual a robustez de uma rede em caso de perda de informação, dados incorretos, perda de neurônios ou sinapses e mal funcionamento?*
- j) *que classes de funções as redes são capazes de aprender?*

2.4.4 *Paradigmas e Proposta de Investigação*

Todas as questões discutidas neste capítulo mostraram quais são os paradigmas no campo das redes neurais:

- (1) redes neurais artificiais são formadas por arranjos regulares de unidades interconectadas por pesos que produzem ganhos lineares: *o que é diferente dos sistemas biológicos*;
- (2) as funções de transferência são funções do tipo *sigmóide* ou *tangente hiperbólica*, ou ainda outras funções que saturam em limiares pré estabelecidos; e,
- (3) a tarefa de aprendizado em geral é tratada de forma separada da arquitetura da rede: *também sem analogia biológica*.

Com base nesses paradigmas pode ser feita uma proposta de investigação que *aproveite mais a natureza evolucionária dos sistemas biológicos, tanto no desenvolvimento arquitetônico quanto nos processos de treinamento das redes neurais artificiais*.

Para desenvolver essa investigação, o primeiro passo a ser dado deverá ser baseado nas mais recentes pesquisas da neurofisiologia, focalizando os seguintes aspectos:

1. a organização do cérebro e o fluxo de informações;
2. as funções de transferência neuronais; e,
3. os mecanismos de memória e aprendizado.

Esses aspectos, nessa mesma ordem, serão abordados no próximo capítulo.

3 PESQUISA NA NEUROFISIOLOGIA

Este Capítulo apresenta os resultados das pesquisas em neurofisiologia, mostrando a relação observada entre funções biológicas e componentes equivalentes em redes neurais artificiais. Muitos detalhes que serão apresentados poderiam ter sido omitidos, no entanto não o foram, pois detalhes desse tipo é que levaram às inovações propostas e, esses mesmos detalhes ainda poderão ser úteis no futuro prosseguimento das pesquisas nesta linha. Há que se destacar que a primeira fonte de informação neste tema de pesquisa foi o livro de Kandel, Schwartz e Jessel, de 1990, a partir do qual diversas outras fontes foram consultadas, sendo referenciadas no momento de sua citação.

A foto da Figura 3.1 exibe a estrutura de um pequeno circuito nervoso ilustrando como a formação desse intrincado sistema pode ser diferente da uniformidade geométrica e da limitada conectividade das redes neurais artificiais tradicionais. De fato, essa grande diferença observada foi um dos fatores determinantes para o início desta pesquisa na área da *neurofisiologia*.

O desenvolvimento da eletrônica nas duas últimas décadas permitiu um crescente desenvolvimento nas pesquisas sobre as estruturas do cérebro e também forneceu máquinas potentes para a solução de problemas numéricos complexos, abrindo oportunidades para a exploração dos aspectos evolucionários do cérebro, motivo do próximo item.

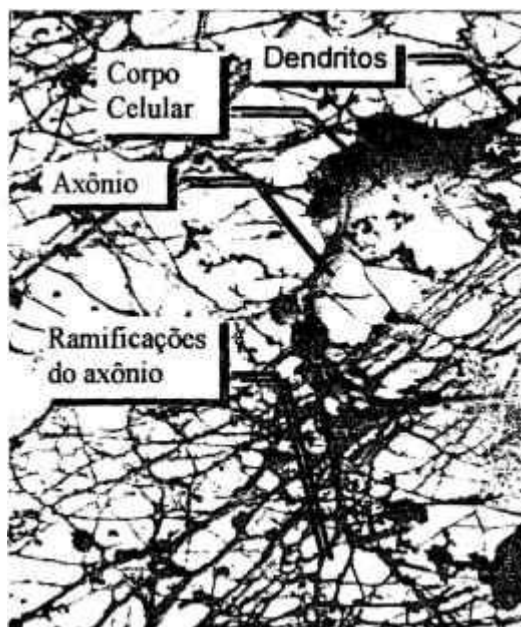


Figura 3.1 - Microestrutura de um circuito nervoso.
 (adaptação de foto da *Eye of Science/Science Photo Library*,
 da edição de fevereiro de 1998 da revista *Superinteressante*)

3.1 *O Princípio Evolucionário do Processamento Neuronal*

O cérebro humano processa informações de um modo seqüencial e lógico em termos de símbolos (Shun-Ichi Amari, 1990), através de um processo paralelo e extremamente dinâmico. As diferentes regiões do cérebro são especializadas em funções específicas e a interligação dessas regiões funcionais propiciam o desenvolvimento de funções de maior complexidade. Apesar dessas regiões serem especializadas em funções determinadas, observam-se circuitos semelhantes em várias delas. Dentro de cada uma dessas regiões são encontrados diferentes tipos de circuito, notando-se porém a existência de princípios básicos, cuja compreensão foi de fundamental importância para este trabalho.

Os princípios do processamento paralelo surgiram de processos evolucionários aleatórios guiados por duplicação de genes, mutação e até mesmo simbiose. Diferencia-

ção e estratégias adaptativas se desenvolveram para aumentar a velocidade de reação e a capacidade global dos organismos.

Desse intrincado processo de evolução culminou a organização do sistema nervoso humano, constituído por diferentes circuitos que têm sua consolidação iniciada ainda no desenvolvimento embrionário. O cérebro humano, através da organização de sua conectividade neuronal, nos permite ver, ouvir, memorizar, sentir emoções e até mesmo planejar o futuro. Grande parte dessa organização vem previamente projetada pela natureza, não se tratando de uma organização individual que surge ao acaso. As redes de neurônios são geradas nas posições e proporções exatas por meio de mecanismos gravados no DNA em diferentes períodos da evolução.

Essa observação de que as diferentes regiões do cérebro se desenvolveram em períodos diferentes da evolução e o fato de apresentarem anatomia distinta, auxiliou inclusive a investigação dos princípios de sua organização, apresentados a seguir.

3.2 *Princípios de Organização do Cérebro*

Gall (1810) já postulava que o cérebro não era um único órgão, mas uma coleção de pelo menos 35 *domínios*, ou centros, cada um correspondendo a uma função mental específica. Por isso, para ilustrar os caminhos percorridos durante a pesquisa de trabalhos sobre a organização do cérebro humano, é conveniente uma simplificação, mencionando apenas as principais macro-divisões anatômicas e funcionais, como vistas atualmente.

As Figuras 3.2 e 3.3 mostram essas divisões no aspecto anatômico, e a Figura 3.4 associa parte dessas divisões a um dado aspecto funcional.

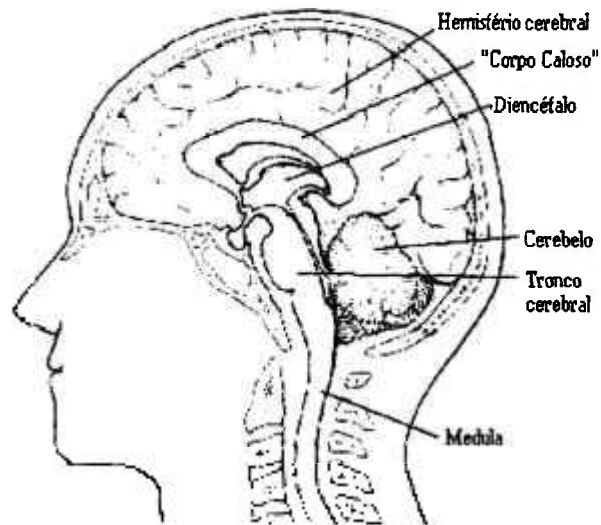


Figura 3.2 - Vista centro-lateral do cérebro humano (Kandel, 1991a).




Figura 3.3 - Grandes regiões do cérebro (Kandel, 1991a).

A parte mais central do cérebro é formada por quatro estruturas interligadas: a medula espinhal, o conjunto tronco cerebral e cerebelo, o diencefalo e os hemisférios cerebrais. A medula espinhal está ligada a essa parte central e tem funções apenas indireta-

mente ligadas às atividades nervosas superiores, apesar de desempenhar um papel fundamental no sistema motor que será o foco deste trabalho.




Figura 3.4 - Principais localizações funcionais (Kandel, 1991a).

O intrincado sistema constituído por essas regiões pode ser analisado sob um enfoque mais restrito, que exponha os fatores que influem na organização do cérebro. Dentro dessa linha é importante considerar a macro divisão funcional mais elementar do sistema nervoso, que de acordo com Claude Ghez (1991) é constituída por duas classes de planos: um para as *percepções sensoriais* e outro para *comandos motores*.

As percepções sensoriais se originam no *sistema sensorial* que constrói uma representação interna do mundo exterior. Uma função dessa representação é extrair a informação necessária para guiar os movimentos que fazemos. A percepção é uma organização precisa das propriedades essenciais de um objeto que nos permite manipulá-lo com sucesso. Para construir a representação interna desses objetos, os sistemas sensoriais mediam

quatro atributos do estímulo: a *modalidade*, que é a sensação definida pelos sentidos da visão, audição, tato, paladar e olfato; a *intensidade*, que em geral é correlacionada com a intensidade dos estímulos e é afetada tanto pela prática como pela fadiga e ainda pelo contexto em que os estímulos são apresentados; a *duração*, que se prolongada pode inclusive diminuir a intensidade da sensação através da adaptação; e a *localização*, que depende das habilidades de se localizar a região do estímulo e de se discriminar dois estímulos próximos.

A representação interna dos objetos e do ambiente elaborada pelo sistema sensorial é utilizada para controlar os movimentos por meio de um conjunto de sistemas motores que nos permitem manter equilíbrio e postura, e mover nosso corpo, membros e olhos e ainda nos comunicarmos através da fala e dos gestos. A informação sensorial é usada para corrigir erros através de mecanismos de realimentação (“feedback”) e de pré-alimentação (“feed-forward”). A realimentação é usada para manter ou para modular uma variável, como uma posição ou uma força, e no desempenho de movimentos lentos. Por outro lado, quando a variável deve ser mantida em torno de um ponto de ajuste, um sinal de referência é mantido constante em um processo chamado de *regulação*. Quando é necessária a previsão de uma determinada variável os sistemas motores utilizam mecanismos de pré-alimentação, ou seja, utilizam controle adaptativo como o caso do reflexo dos joelhos, que é essencial para movimentos rápidos e para lidar com mudanças temporais causadas pela fadiga, por exemplo.

Para desenvolver a mais simples tarefa, o sistema motor precisa conduzir comandos de controle precisos e sincronizados para muitos grupos de músculos, que devem contrair ou relaxar considerando a distribuição de massa do corpo, fazendo os necessários ajustes de posição e, levando em conta o arranjo físico dos músculos, ossos e juntas. Para

desempenhar essas tarefas os sistemas motores são organizados em uma hierarquia de níveis de controle em que, cada nível recebe continuamente um adequado fluxo de informações sensoriais.

Em função dessa organização hierarquizada, os níveis mais elevados dos sistemas motores podem se concentrar em questões estratégicas, como a seleção de uma resposta adequada a uma determinada meta sem a necessidade de monitorar, instante a instante, os detalhes da resposta, que podem ser acompanhados por um nível hierarquicamente inferior.

Essa organização em níveis de controle confirma a tese de que o conhecimento não é baseado somente na experiência sensorial, mas também no pré-conhecimento que organiza essa experiência sensorial. Isso significa que o comportamento depende tanto de *fatores genéticos e de desenvolvimento* quanto dos *fatores ambientais*. A pesquisa de Susan Goldin e Carolyn Mylander (1998) mostrou que crianças surdas-mudas, de culturas, origens e etnias diferentes, tendem a usar os mesmos sinais para se expressar, demonstrando que a comunicação gestual, e portanto a linguagem, é uma aptidão previamente programada no cérebro e não apenas um produto da educação.

Isso demonstra que uma investigação mais profunda sobre o desenvolvimento organizacional do cérebro pode mostrar como se tirar o máximo proveito da natureza evolucionária que culminou com a enorme eficácia dos processos mentais humanos.

Seguindo nessa direção, James P. Kelly e Jane Dodd (1991) definem a arquitetura dos circuitos neuronais como governada por um conjunto de princípios funcionais, organizacionais e de crescimento. Nas mais diversas regiões são encontrados circuitos se-

guindo princípios simples como a *divergência*, quando colaterais de um dado neurônio se ligam em diversos neurônios alvo (Figura 3.5); e a *convergência*, quando a atividade de um dado neurônio depende da soma das entradas de inúmeras outras células, como ocorre nas conexões entre células do sistema sensorial com células motoras (Figura 3.6). Circuitos convergentes permitem a uma dada região do cérebro integrar entradas provenientes de diferentes sistemas sensoriais. Circuitos divergentes permitem a pequenos grupos de células propagar sua influência para as mais diversas regiões do cérebro.

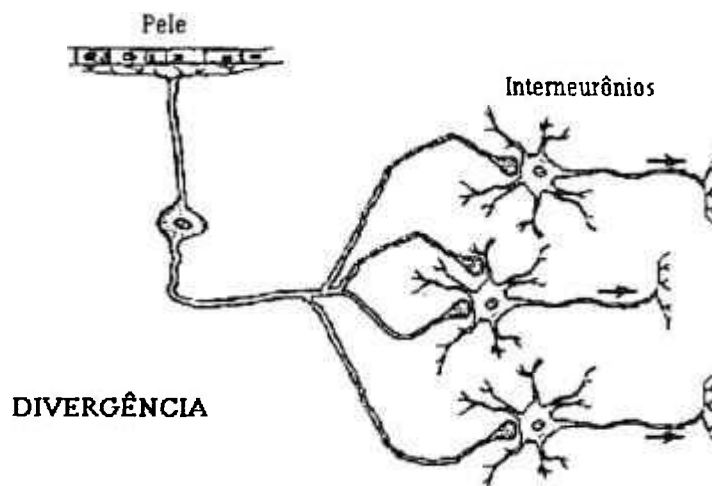


Figura 3.5 - Exemplo de circuito divergente.

A comunicação entre cada célula desses circuitos se processa nos terminais nervosos que se formam nos contatos entre duas células e que são denominados *sinapses*. A especificidade na formação dessas sinapses (contatos sinápticos) é um processo importante que depende de afinidades seletivas entre os neurônios pré e pós-sinápticos, ou seja, a formação de conexões apropriadas e permanentes entre dois neurônios depende do casamento correto de moléculas presentes em ambos. De acordo com Paul Weiss (1948), durante o desenvolvimento do cérebro, a especificidade das conexões neuronais somente ocorre pela retenção seletiva dos contatos nos quais os padrões de atividade elétrica do neurônio pré-

sináptico se casam perfeitamente com os padrões de atividade do neurônio alvo. Dessa visão se originou uma teoria conhecida como a “*hipótese da ressonância*”, que foi muito útil neste trabalho e que será referida novamente durante a apresentação dos novos modelos.




Figura 3.6 - Exemplo de circuito convergente.

A formação dos contatos sinápticos começa no desenvolvimento embrionário com o encontro do que se chama “*cone de crescimento axonal*” com as suas células alvo. O cone que parte de uma dada célula, é guiado pela emissão de substâncias precursoras e, ao atingir uma célula alvo, dispara a formação dos contatos sinápticos que se desenvolvem através de um processo gradual. A formação desses contatos iniciais não é o evento final da formação da intrincada rede que define a conectividade neuronal, nem tampouco pode se afirmar que há uma regra única. Em algumas regiões do sistema nervoso os contatos iniciais entre células são precisos e estáveis, evidenciando um alto grau de especificidade inicial em reconhecimento celular. Em outras regiões contudo, os contatos iniciais acabam sendo eliminados ainda durante os estágios de desenvolvimento e o padrão de conexões que irá

emergir como resultado de reconhecimento celular durante o desenvolvimento pré-natal, apenas grosseiramente se aproxima do padrão de ligações final.

Como resultado do processo de desenvolvimento dos contatos sinápticos, a conectividade neuronal atinge o estágio em que uma única célula, através de seu axônio, forma não uma, mas em média mais de 1000 conexões sinápticas com outras células, recebendo um número equivalente ou maior de conexões de outras células. Um neurônio motor, por exemplo, pode receber 10,000 diferentes contatos e uma célula Purkinje, pode receber até 150,000 contatos (Figura 3.7). No total são formadas em torno de 10^{14} conexões sinápticas em todo o sistema nervoso humano.



Figura 3.7 - Célula Purkinje do Cerebelo (Kandel, 1991c).

A duplicação de vários tipos de associação em diversas regiões do sistema nervoso, mostra outros princípios que regem sua organização: *a)* o chaveamento por meio de interneurônios ilustrado na Figura 3.8, onde um sinal de dor, que usualmente acionaria uma ação reflexiva mas que num determinado instante pode prejudicar uma ação essencial, pode ser bloqueado por um sinal de controle; *b)* o chaveamento por meio de inibição pré-sináptica da Figura 3.9, que produz efeito similar; *c)* a perpetuação de uma informação por meio de circuitos reverberantes, como ilustrado na Figura 3.10; e a geração de um ritmo alternado por circuitos como o da Figura 3.11.

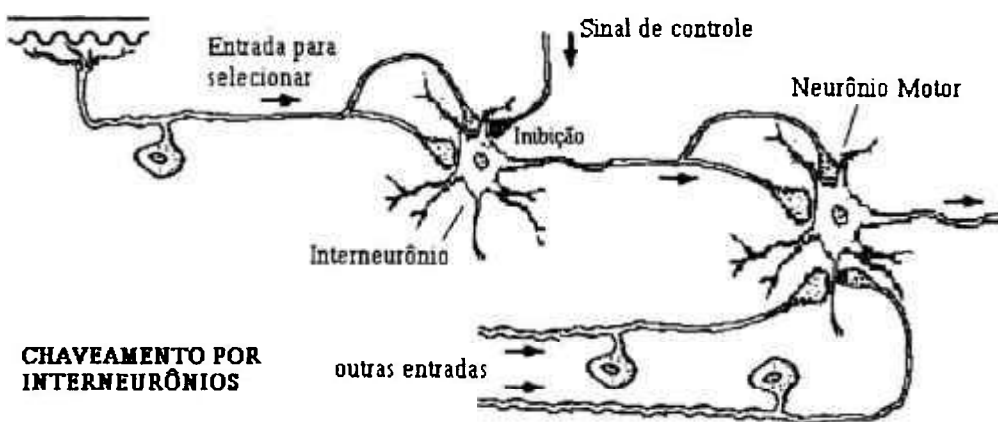


Figura 3.8 - Chaveamento por interneurônios.




Figura 3.9 - Chaveamento por inibição pré-sináptica.

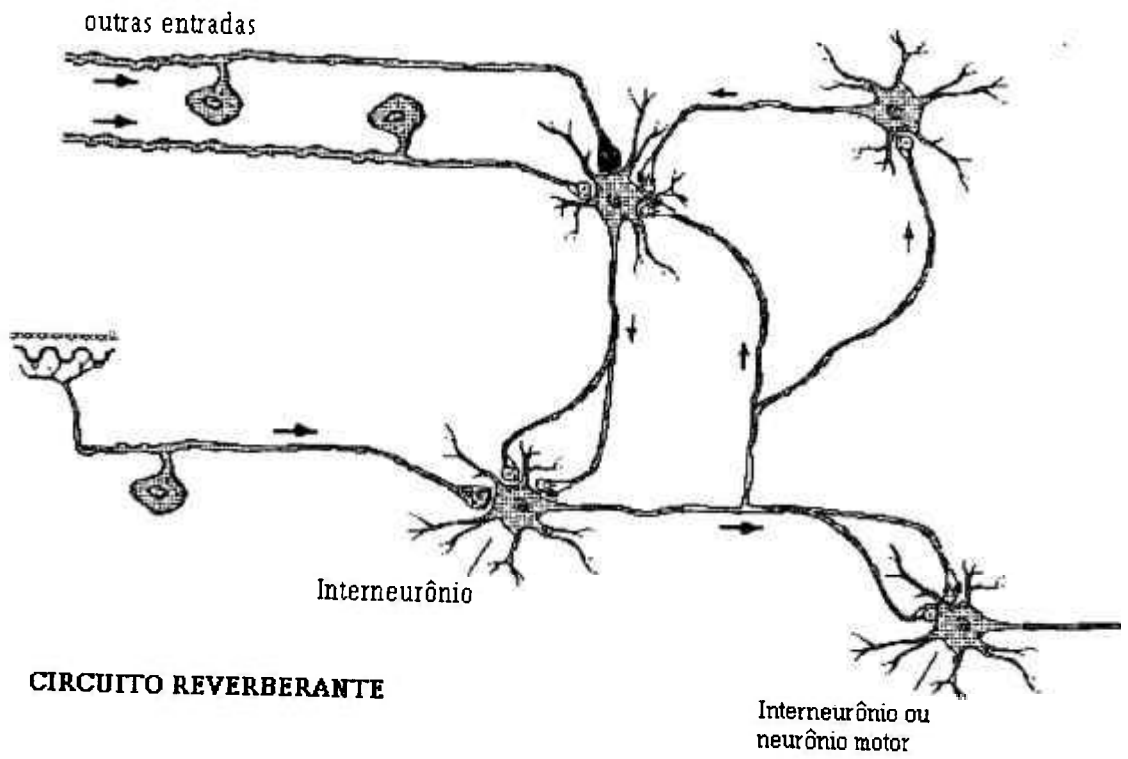


Figura 3.10 - Exemplo de circuito reverberante.

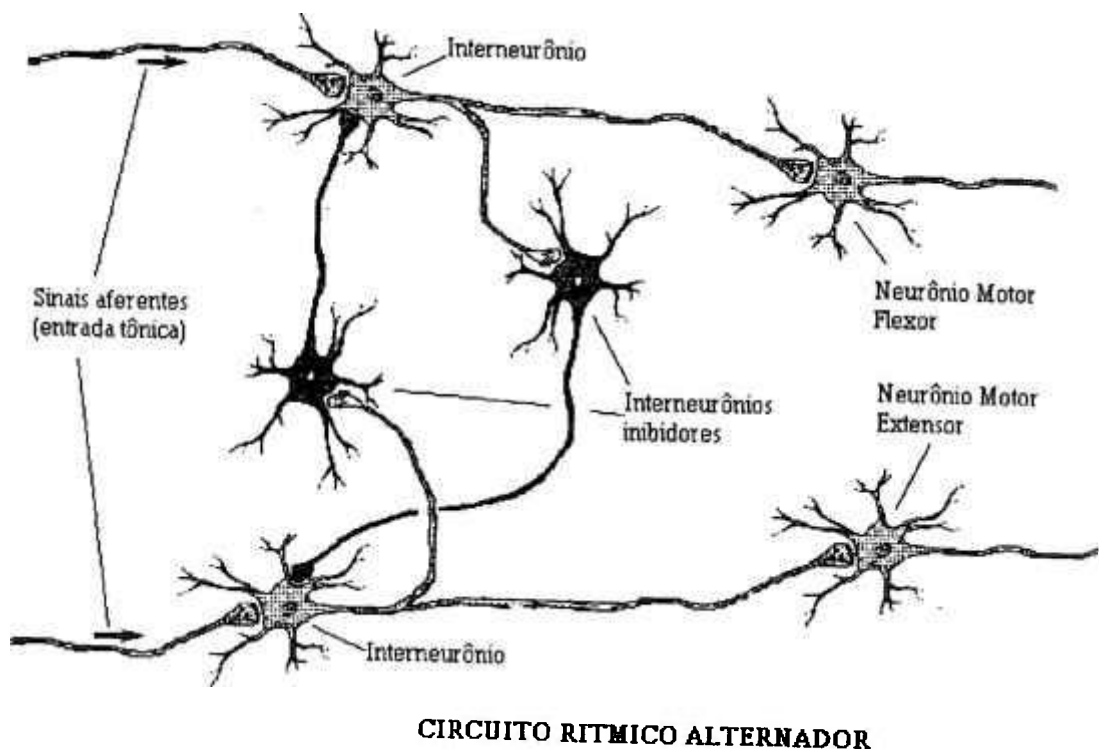


Figura 3.11 - Circuito rítmico alternador.

3.3 Transmissão de Sinais no Cérebro

3.3.1 Sinalização

As células nervosas têm a habilidade de se comunicar entre si por meio de processos precisos e eficazes usualmente chamados apenas de *sinalização*. A sinalização é intermediada por movimentos químicos e elétricos que se processam através de quatro sub-processos: as *entradas* excitatórias ou inibitórias moduladas, o *processo integrativo* que leva à decisão de se gerar ou não um potencial de ação no neurônio, a *condução do potencial de ação* e, a *liberação graduada de neuro-transmissores*. A Figura 3.12 ilustra esses processos de sinalização.

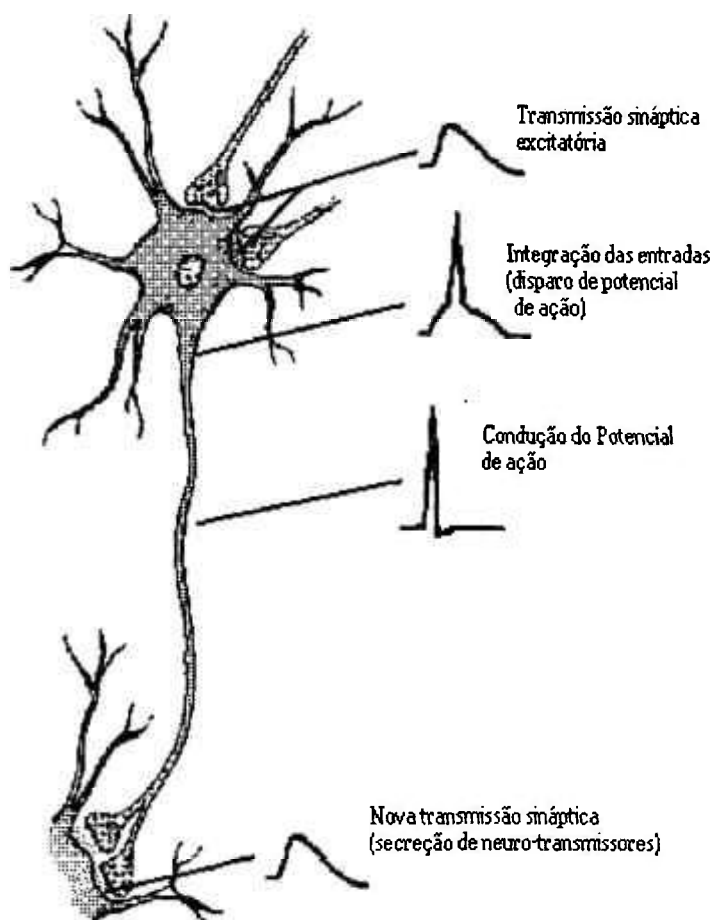


Figura 3.12 - Sinalização neuronal.

Apesar do significado de cada sinal transmitido dentro de um sistema neural ser determinado quase que exclusivamente pelos caminhos neurais ativados por um dado estímulo, em função dos diferentes processos de transmissão, os diferentes tipos de neurônios podem codificar o mesmo impulso em padrões completamente diferentes, gerando portanto diferentes padrões de saída. Além do tipo de neurônio, outro aspecto que afeta o significado dos sinais é o tamanho da população de neurônios de um dado circuito, que pode ser mais ou menos significativo na ativação de uma resposta. Neste aspecto a população de neurônios apresenta uma importância adicional ao papel de robustez por redundância.

3.3.2 Transmissão Sináptica e Potencial Pós-Sináptico

Considerando o aspecto individual de cada célula nervosa, o processo de sinalização denominado *transmissão sináptica* é provavelmente o mais importante para o aprendizado. Esse processo é desempenhado por meio de diversos mecanismos existentes nos terminais nervosos, que são essenciais até mesmo para a sobrevivência das células nervosas. Em função do mecanismo de sinalização nas sinapses, elas podem ser classificadas em: *sinapses elétricas*, nas quais a transmissão é efetuada diretamente entre o conteúdo iônico da célula pré-sináptica e o da célula pós-sináptica; e *sinapses químicas*, nas quais não ocorre o contato do citoplasma entre as células e a transmissão é intermediada por um neuro-transmissor.

As sinapses elétricas são menos comuns, principalmente nos animais mais evoluídos. Têm uma característica de resposta mais rápida, não são comuns em inibição e não são suscetíveis a adaptação (mudanças de efetividade com aprendizado). Os comportamentos mediados por sinapses elétricas apresentam características de alto limiar e ocorrên-

cia explosiva, típicos de situações que envolvem respostas defensivas e escape. Por outro lado, as sinapses químicas atuam tanto em excitação quanto em inibição, permitem amplificação e funcionam em comportamentos mais complexos. São *flexíveis*, ou seja, são suscetíveis a alterações de efetividade, participando em processos de memorização e outras funções mais elevadas.

As sinapses químicas, responsáveis por importantes atividades cerebrais como a memória e o aprendizado, predominam no nosso sistema nervoso. Nas sinapses químicas a sinalização é processada por mensageiros químicos denominados transmissores, que são liberados nos terminais pré-sinápticos em função do fluxo de potenciais de ação que percorrem o axônio. Um importante transmissor no sistema motor é a acetilcolina (Ach), que nos textos adiante será mencionada apenas como “*transmissor*” a menos que explicitamente indicado outro neuro-transmissor. A porção de transmissor liberada durante a chegada de uma série de potenciais de ação atua sobre um grande número de receptores, *os canais de íons da célula alvo* (Figuras 3.13 e 3.14). São esses receptores (e não a célula pré-sináptica) que determinam se a sinapse é excitatória ou inibitória.

A atuação de cada um desses canais gera uma pequena corrente elétrica na membrana pós sináptica, causada pelo fluxo de íons de sódio e íons de potássio principalmente. Experimentos realizados por Sakmann e Neher(1983) mostraram que a distribuição das amplitudes dos pulsos de corrente no músculo de uma rã é uma curva normal em torno do valor de 2,7 pA (Figura 3.15). A amplitude dessa corrente de íons tem um valor relativamente constante entre os diversos canais, porém a duração da abertura dos canais é governada por um processo estocástico, variando de abertura a abertura. Apesar do número de canais abertos durante o desenvolvimento de um potencial sináptico ficar limitado pela

quantidade de transmissor disponível, o recrutamento dos canais chaveados por tensão proporciona mecanismos moduladores e amplificação dos sinais.

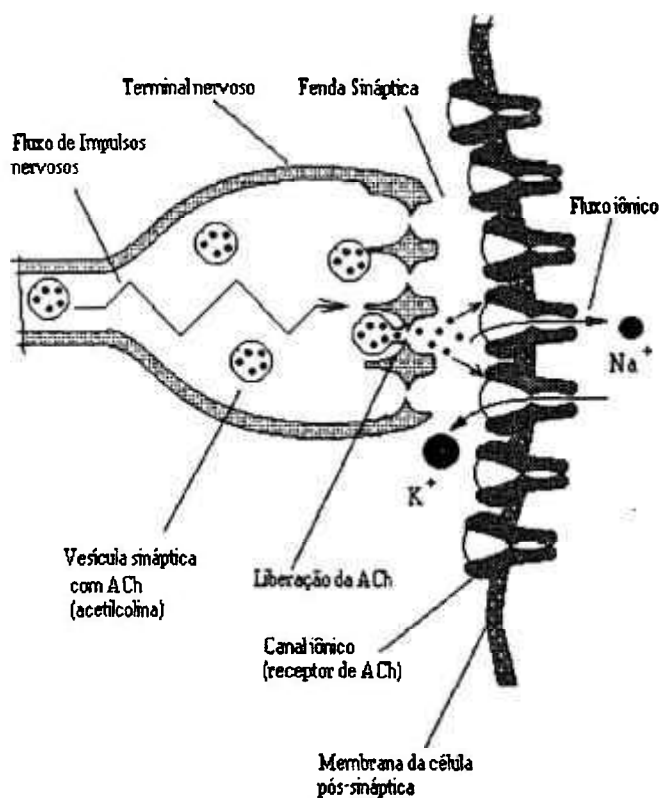


Figura 3.13 - Esquema simplificado de Sinapse Química de ACh.




Figura 3.14 - Ampliação de um aglomerado de canais iônicos de ACh. (adaptado de Heuser e Salpeter, 1979)

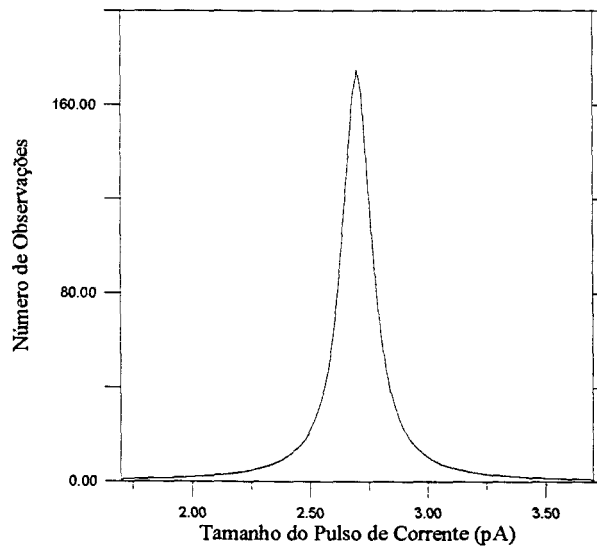


Figura 3.15 - Distribuição de pulsos de corrente em uma junção neuro-muscular.

O aspecto estocástico da efetividade dos processos de transmissão sináptica, não só devido à limitação quantitativa de moléculas de transmissor e ao número de canais, suscita um outro aspecto da sinalização sináptica, peculiar a praticamente todo o sistema nervoso: *praticamente nenhum neurônio pré-sináptico é capaz, sozinho, de excitar uma célula pós-sináptica o suficiente para atingir o limiar de disparo de um potencial de ação* (Stevens, 1994). Esse aspecto define o princípio de *cooperatividade*, presente em todo o sistema nervoso.

A contribuição relativa de uma dada sinapse, excitatória ou inibitória, no conjunto de entradas de uma célula depende ainda da sua localização no neurônio pós-sináptico, do seu tamanho e formato, além da proximidade e força relativa de outras sinapses sinérgicas ou antagonistas. Esse efeito de *soma espacial* é quase tão crítico quanto a própria organização dos circuitos neuronais. Por outro lado, a grande constante de tempo de um neurônio é explorada na zona de integração do neurônio, onde os sinais de entrada na célula são ponderados temporalmente, em períodos de muitos milissegundos. Esse outro efeito é denominado de *integração temporal*.

A composição dos mecanismos atuantes na transmissão sináptica mediada pela ACh gera um comportamento que, a menos de alguns processos importantes para os mecanismos de plasticidade que ainda não serão abordados, pode ser descrito da seguinte maneira: 1) a chegada de uma série de potenciais de ação no terminal nervoso provoca, por meio da exocitose (a “fusão” das vesículas sinápticas nos canais da membrana do terminal), a liberação da ACh contida nas vesículas sinápticas recrutadas, proporcionalmente à duração da série de potenciais; 2) a migração da ACh e sua atuação em uma determinada quantidade de canais receptores da célula alvo, que por sua vez é proporcional à quantidade de ACh e à disponibilidade de canais não bloqueados por inibidores; 3) a abertura dos canais atuados por transmissor com o conseqüente fluxo iônico intra- e extra-celular (Na^+ adentrando a célula pós-sináptica e K^+ saindo desta) que provoca a mudança no potencial sináptico e promove o recrutamento dos canais chaveados por tensão; 4) o disparo ou não de um potencial pós-sináptico, se nada impedir que sejam atingidas as condições para tal; e, 5) a condução desse possível potencial no interior do corpo celular, em direção ao ponto de disparo de potenciais de ação do neurônio.

Esse comportamento é bem conhecido desde a divulgação dos experimentos de Hodgkin e Huxley (1952) e pode ser simulado por meio de modelos bem precisos. Para ilustrar o resultado do processo de transmissão sináptica sobre uma célula pós-sináptica, foi realizada uma simulação utilizando o programa C-CLAMP (John Huguenard e David A. McCormick, 1994). A simulação consistiu na injeção de dois sinais de corrente em uma célula, simulando a atuação de um terminal sináptico: um abaixo do limiar necessário para disparar um potencial, ou seja, insuficiente para recrutar o mínimo número de canais chaveados necessários; e outro sinal suficientemente alto para disparar um potencial pós-sináptico. A sobreposição dos resultados dessa simulação pode ser vista na Figura 3.16.

A importância desses resultados, apesar de não evidente, foi a conclusão de que um modelo para representar adequadamente o processo de transmissão sináptica, deve possuir algum tipo de dispositivo de resposta sujeita a *limiares*.

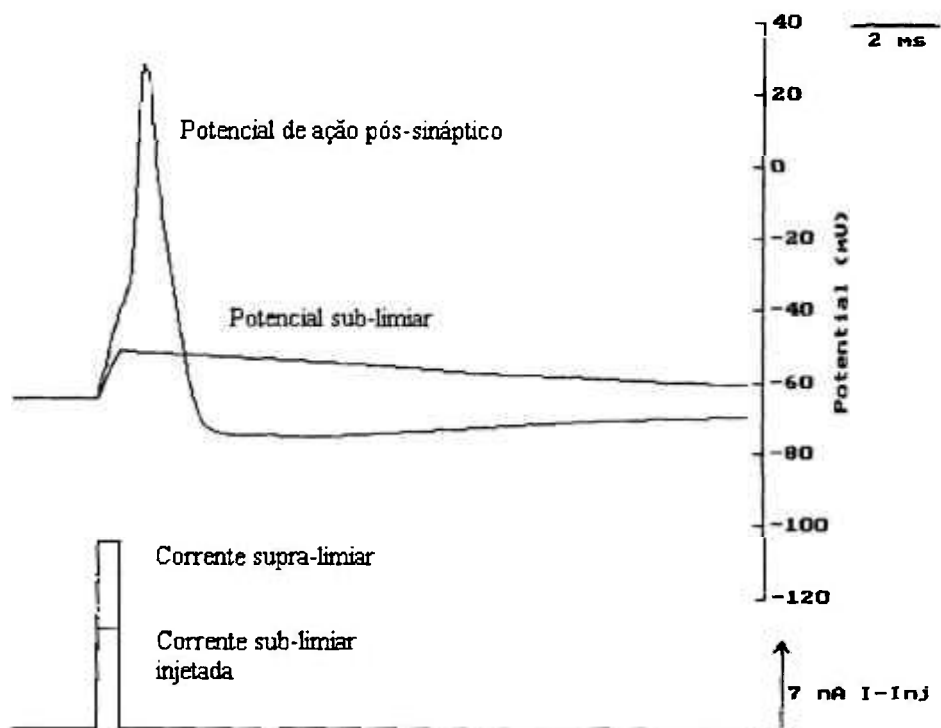


Figura 3.16 - Potencial de ação pós-sináptico.

3.4 O Aprendizado e os Mecanismos da Memória

Compreendidos os processos de transmissão de sinais no cérebro, é necessária a compreensão dos processos de aprendizado e memória, aos quais será dedicado um maior espaço pois neles se concentra a maior essência das inovações propostas.

Aprendizado é o processo de aquisição de conhecimento sobre o mundo e memória é o armazenamento desse conhecimento. A memória pode ser classificada pelo modo como as informações são estocadas e recuperadas em: *memória reflexiva* e *memória declarativa* (Irving Kupfermann, 1991). Memória reflexiva é o armazenamento acumulativo

e lento da informação através da repetição de muitas e muitas apresentações. Memória declarativa é aquela estabelecida durante uma única tentativa ou experiência. A lembrança de fatos ou eventos presenciados uma única vez e que podem ser relatados é o exemplo típico de memória declarativa. A situação vivenciada ativa o sistema sensorial gerando impulsos nervosos que atingem as regiões mais altas do cérebro, no córtex cerebral onde são desempenhadas as funções mais evoluídas. Esses impulsos “impressionam” o caminho por que passam fortalecendo conexões entre neurônios de modo que o cérebro possa recriar futuramente a impressão causada por essa situação. Essas sensações podem então ser reproduzidas, sempre que necessário e nesse caso serão reforçadas. Quando solicitado, o sistema nervoso envia novos impulsos pelo mesmo caminho, reproduzindo as impressões armazenadas, num processo conhecido como *memória associativa*. Qualquer tipo de estímulo, ou uma combinação deles, reativa os padrões de conexão estabelecidos nessa experiência.

Kupfermann professa que a base neural da memória pode ser resumida em quatro princípios: *a memória tem estágios e está continuamente mudando; a memória de longa duração pode ser representada por mudanças plásticas no sistema nervoso; as mudanças físicas que codificam a memória não são localizadas em uma única região; e, memórias reflexiva e declarativa podem envolver diferentes circuitos neuronais.*

Ao contrário do que se imaginava no passado, não existe uma região específica para a memória. De um modo geral no entanto, a formação da lembrança e o armazenamento inicial de fatos experimentados ocorre na região do hipocampo. Na amígdala são registradas as impressões de medo e alerta, no gânglio basal, as informações de hábitos e habilidades. A memória rápida ocorre no córtex e em suas conexões.

Essa natureza fragmentada dos arquivos de memória permite o refinamento das impressões, reforçadas por novos estímulos em associação, e por outro lado, também permite o seu esquecimento.

A memória está ligada ao aprendizado, ou seja, à capacidade de repetir os sucessos e evitar as ações que levam a erros já cometidos. O aprendizado por sua vez pode ser avaliado submetendo um indivíduo a repetidas experiências e acompanhando o progresso na mudança de seu desempenho.

3.4.1 *Processos de Aprendizado*

Como constata as pesquisas da neurofisiologia, o desenvolvimento do cérebro passa por diversos estágios. A migração de precursores neuronais nos primeiros estágios do desenvolvimento embrionário desempenha importante papel no estabelecimento da identidade de alguns neurônios, na definição de futuras conexões, e possivelmente determina suas propriedades funcionais. Durante o desenvolvimento pré-natal ocorre a migração e o início do crescimento dos neurônios. Tão logo um neurônio atinja sua posição final, começa a estender um axônio que cresce e é dirigido para fazer conexões com outras células, organizando-se em redes de processamento. A partir desse ponto as interações com o ambiente local irão propiciar a consolidação da identidade e função do neurônio. Quando recém-nascido o indivíduo tem mais do que todos os neurônios que utilizará até o final da sua vida adulta. As mudanças físicas e químicas a que é sujeito logo após o nascimento desencadeiam novos processos que aceleram o desenvolvimento das funções cerebrais. Esses processos fazem com que os neurônios e suas conexões cresçam em tamanho, fortaleçam conexões e ainda estabeleçam novas conexões. Após a primeira estrutura organizada, o sistema nervoso tem ainda a habilidade de modificar as ligações pelo aprendizado, através de

mecanismos dependentes de atividades neuronais que casam perfeitamente os neurônios pré-sinápticos com suas células alvo. Esse casamento ativo-dependente pode ser modulado pela experiência sensorial no processo de aprendizado. Porém, para que ocorram essas modificações, e para que as mesmas resultem no desenvolvimento cerebral utilizando todo o potencial herdado, é necessário que as atividades cerebrais sejam estimuladas. Essa fase inicial é fundamental para a estruturação das funções cerebrais, conferindo uma fundamental importância à experimentação e aos processos de aprendizado. A estimulação cerebral ajuda a estabelecer e refinar conexões e a sofisticá-las. Sem essa estimulação os neurônios atrofiam e morrem.

Observado sob o prisma dos processos pós-natais, o aprendizado pode ser dito *associativo*, quando o organismo aprende a relação entre um estímulo e outro, ou *não-associativo*, quando o organismo é exposto a um único tipo de estímulo.

O enfoque microscópico dessa questão mostra que um conjunto de sinapses pode ser modificado em dois diferentes modos de aprendizado: as sinapses podem ter sua força de ligação diminuída pela *habituação* ou aumentada pela *sensitização*. Dois processos mais complexos ainda são conhecidos, o *condicionamento clássico (CC)* e a *prática*.

- *habituação*: A habituação é a mais simples forma de aprendizado. É um processo não-associativo no qual um ser aprende sobre as propriedades de um estímulo novo e indolor, quando esse estímulo é repetido várias vezes. O indivíduo primeiro responde a um novo estímulo com uma série de reflexos orientativos, quando o estímulo é repetido o indivíduo aprende a reconhecê-lo e se o estímulo não é doloroso nem agradável, aprende a suprimir qualquer tipo de resposta ao mesmo. Essa supressão de resposta aprendida para um estímulo repetido é a chamada *habituação*.

Spencer, Thompson e Neilson (1966) descobriram que em certas formas de comportamento reflexivo, a habituação produz um decréscimo na atividade sináptica entre interneurônios e neurônios motores, sem uma correspondente redução da atividade nos caminhos mono-sinápticos subjacentes ao reflexo. Estudos com a habituação do reflexo de contração da guelra da lesma do mar mostraram que os potenciais sinápticos produzidos pelos neurônios sensores nos interneurônios e nas células motoras ficavam progressivamente menores. Os potenciais sinápticos produzidos por alguns dos interneurônios nos neurônios motores também enfraqueceram com o resultado líquido de redução da força de resposta reflexiva.

O decréscimo na transmissão sináptica dos neurônios sensores resulta de um decréscimo nas quantidades de transmissor liberado pela ação dos potenciais de ação nos terminais pré-sinápticos. Essa redução na efetividade das conexões sinápticas entre os neurônios sensores e suas células alvo pode durar por vários minutos. Observou-se que nos animais mantidos para controle, 90% dos neurônios sensores fazem conexões detectáveis com um dado neurônio motor, enquanto que em animais submetidos à habituação a incidência de conexões detectáveis é reduzida a 30%. Essa desativação de longa duração é acompanhada de mudanças estruturais nas células sensoras, como ilustra a Figura 3.17.

Mudanças duradouras também ocorrem nas conexões sinápticas entre diversos interneurônios e neurônios motores dentro desse circuito. Essas mudanças representam componentes do processo de armazenamento de memória de curta duração na habituação. As mudanças sinápticas que ocorrem nas conexões entre interneurônios e neurônios motores são similares às que ocorrem entre os neurônios sensores e os neurônios motores.

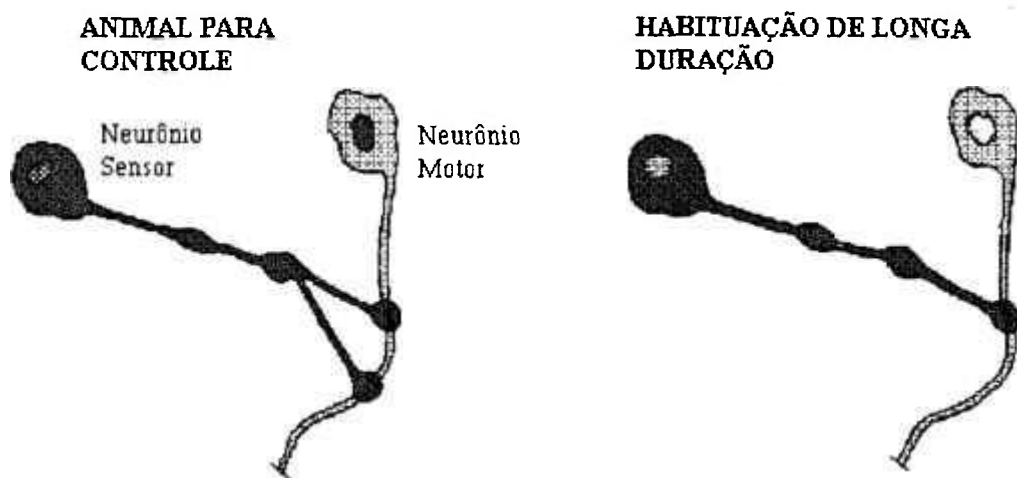


Figura 3.17 - Efeito do mecanismo de habituação (Kandel, 1991b).

- sensitização: Enquanto a habituação produz uma *depressão homosináptica*, ou seja, um decréscimo na força de transmissão sináptica resultante da atividade do caminho estimulado, a sensitização produz uma *facilitação heterosináptica*, ou seja, um aumento na força de transmissão sináptica. Na sensitização um indivíduo aprende sobre as propriedades de um estímulo doloroso e, como resultado, se lembra de responder mais efetivamente a uma variedade de outros estímulos mesmo sendo inócuos. A sensitização é uma forma mais complexa de aprendizado não-associativo que a habituação mas também apresenta duas componentes, uma de curta duração e outra de longa duração, durando dias e mesmo semanas, dependendo do número de estímulos apresentados. Os estímulos sensitizantes ativam um grupo de interneurônios facilitadores ligados aos neurônios sensores. Os neurônios facilitadores produzem ligações axo-axônicas que ampliam a liberação de transmissores pelos neurônios sensores. A ilustração esquemática do circuito neuronal da lesma do mar suscetível à sensitização é mostrado na Figura 3.18. A Figura 3.19 mostra um outro efeito do mecanismo da sensitização, o aumento de terminais nervosos.

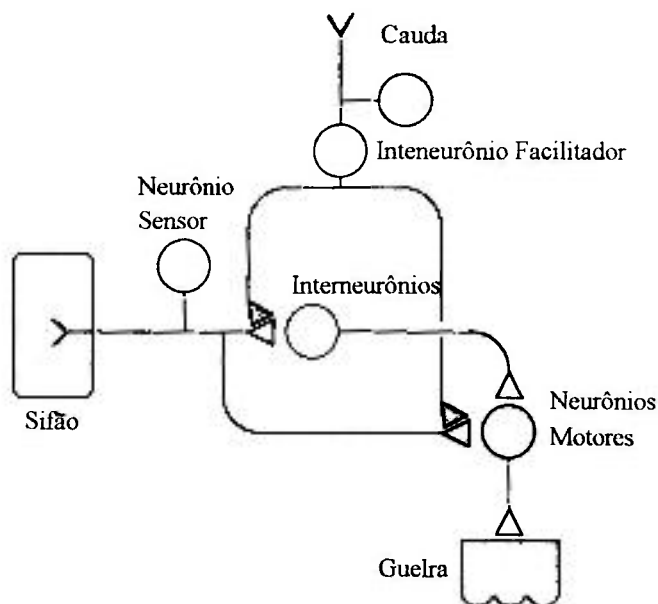


Figura 3.18 - Circuito neuronal envolvendo a sensitização.
(adaptado de Kandel, 1991b)

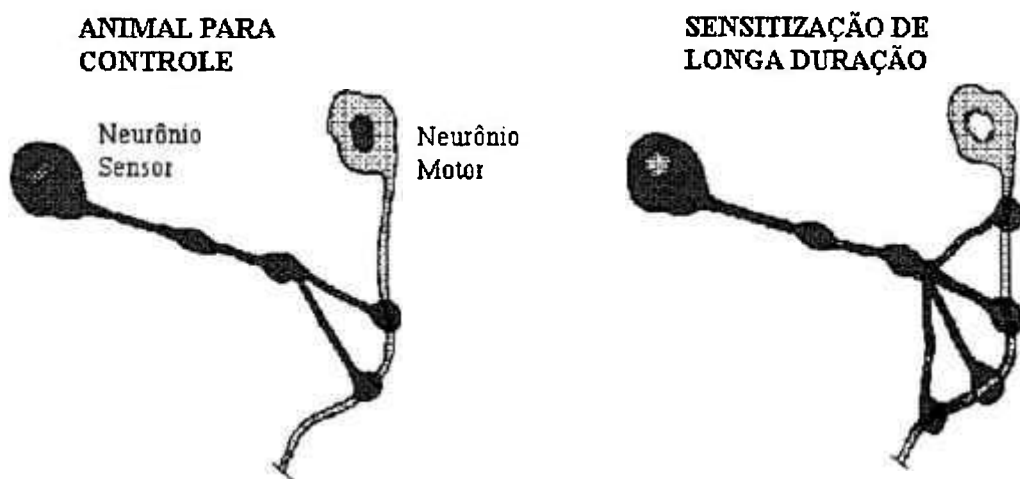


Figura 3.19 - Mecanismo de Sensitização (Kandel, 1991b).

- condicionamento clássico: Condicionamento clássico (CC) é uma forma ainda mais complexa de aprendizado do que a sensitização. No condicionamento clássico, ao invés de se preocupar com as propriedades de um único estímulo, o sujeito deve aprender a relação entre dois estímulos, associando um com o outro. No condicionamento clássico-

co, um estímulo inicialmente fraco ou inefetivo se torna altamente efetivo em produzir uma resposta após ser associado com outro estímulo forte não condicionado.

Para reflexos que podem ser modificados por ambos os processos, sensitização e condicionamento clássico, este último é mais efetivo no aumento da efetividade da resposta e também produz resultados mais duradouros. De fato, pelo menos em alguns casos, observou-se que o mecanismo do condicionamento clássico é uma elaboração da estratégia celular da sensitização.

A Figura 3.20 mostra um diagrama simplificado das mudanças nos caminhos monossinápticos envolvidos no condicionamento clássico da contração da gúelra e do tubo emissor de tinta (sifão) da lesma do mar, um típico exemplo de reflexos que podem ser aumentados por ambos mecanismos, o CC e a sensitização. Um estímulo condicionado (EC^+) aplicado ao manto é aplicado simultaneamente a um estímulo não condicionado (NC) aplicado na cauda. Como controle, um EC^- aplicado no sifão imediatamente antes do NC (não é emparelhado ao NC). O NC é um choque na cauda que excita interneurônios facilitadores que se ligam aos terminais pré-sinápticos dos neurônios sensores no caminho do manto ao sifão. Esse é o mecanismo de sensitização. Contudo, quando o caminho do manto é ativado pelo EC^+ imediatamente antes do NC, os neurônios são premidos a responder de uma maneira amplificada a subseqüentes estimulações pelos interneurônios facilitadores no caminho do NC. Esse é o mecanismo do condicionamento clássico; ele amplifica a resposta do caminho do EC^- e restringe essa amplificação a esse caminho.

O CC envolve o fortalecimento associativo da facilitação pré-sináptica que é dependente da atividade. Os reflexos de contração podem ser despertados tanto pela estimulação no sifão quanto pela estimulação de uma estrutura próxima, como o manto. Cada

uma dessas áreas é enervada por sua própria população de neurônios sensores. Cada caminho pode ser condicionado independentemente pelo emparelhamento de estímulos a ambos, o sifão ou o manto, com um estímulo não condicionado (um forte choque na cauda). O outro caminho pode ser estimulado como um controle que não é emparelhado com o choque na cauda. Após tal tipo de treinamento, a resposta à estimulação da estrutura condicionada é significativamente maior do que aquela da estrutura não condicionada.

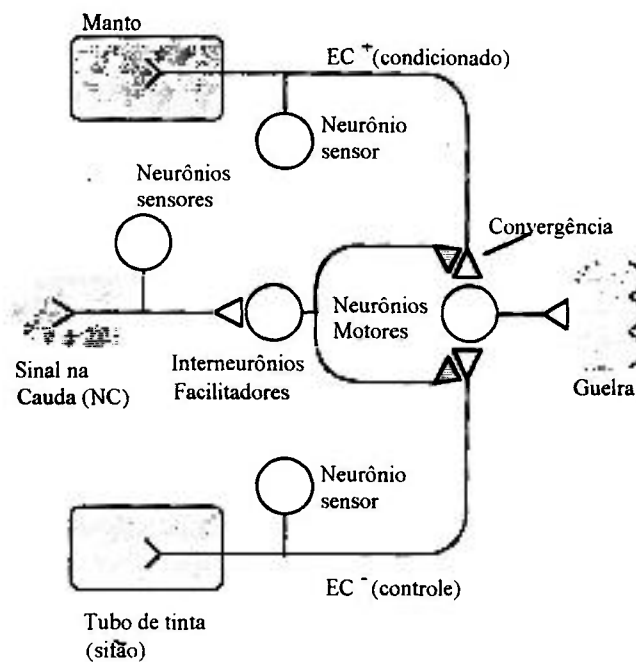


Figura 3.20 - Mecanismo de Condicionamento Clássico (Kandel, 1991b).

Diferente do que ocorre no aprendizado não associativo, o tempo é crítico no aprendizado associativo. Para o CC trabalhar, o estímulo condicionado deve preceder o estímulo não condicionado e frequentemente, como com o estímulo não condicionado desagradável, ele deve ser aplicado dentro de um intervalo de tempo crítico de aproximadamente 0,5 segundo. No condicionamento clássico do reflexo de contração da gueira da lesma do mar, a especificidade temporal de sincronismo resulta da convergência dos estímulos, condicionado e não condicionado, em neurônios sensores individuais. Os interneurônios fa-

cilitadores que são ativados pelo estímulo não condicionado produz uma maior facilitação pré-sináptica dos neurônios sensores somente quando eles ativam os neurônios sensores imediatamente após o estímulo condicionado ter o disparo dos neurônios sensores. Desse modo a facilitação é amplificada se o estímulo condicionado produzir potenciais de ação nos neurônios sensores imediatamente antes da chegada do estímulo não condicionado. Essa propriedade de facilitação pré-sináptica é chamada de *dependência de atividade* (facilitação ativo-dependente). Em contraste, a atividade nos neurônios sensores que segue o estímulo não condicionado não produz um efeito facilitador. Isso confirma que o mecanismo celular do CC do reflexo de contração na lesma do mar é um aprimoramento da facilitação pré-sináptica, o mecanismo de sensitização do reflexo.

O fato de que os mecanismos celulares do condicionamento clássico são um aprimoramento dos mecanismos envolvidos na sensitização sugere que formas mais complexas de aprendizado podem ser construídas por meio da combinação de componentes moleculares de formas mais simples de aprendizado (Kandel, 1991b). Nesse contexto existem ainda outras formas de plasticidade, que em conjunto com a potenciação de longa duração, poderão ser exploradas de alguma forma no campo de redes neurais artificiais.

- *prática*: Como a habituação e outras formas de aprendizado reflexivo, a prática prolonga a memória por sensitização de um modo graduado. Enquanto que uma única seção de treinamento, com a aplicação de 10 estímulos, produz uma sensitização de curta duração, alguns minutos por exemplo, quatro seções de treinamento já podem produzir sensitização de longa duração, durando até um dia. Posteriores repetições desse treinamento podem produzir sensitização que dure até três semanas. Uma descrição interessante desse processo é dada por Kawato, Uno, Isobe e Suzuki (1988), “*a rigidez das conexões do*

sistema nervoso fornece a base para o comportamento instintivo, tais como reflexos e movimentos autônomos, contudo não pode explicar os mecanismos de adaptação, tais como aprendizado e memória. É reconhecido que algumas conexões nervosas do cérebro têm uma certa plasticidade. Quando aprendemos um movimento, primeiro executamos esse movimento vagarosamente, por não ser possível pré-programá-lo adequadamente. Isso é realizado com intervenções do sistema central utilizando a realimentação sensorial. Com a prática, uma grande parte do movimento é programada, passando a ser executada mais rapidamente.”

Os estudos realizados com a lesma do mar e com vertebrados parecem sugerir que a memória de curta duração pode ser decorrente de um único e graduado processo. Observou-se no entanto que algumas condições clínicas decorrentes de um derrame podem afetar seletivamente ou a memória de curta duração ou a memória de longa duração (Kupfermann, 1991). Daniel L. Alkon (1983) mostra resultados de outros experimentos de condicionamento da lesma do mar que demonstram que aprendizados associativos, de duração de vários dias, envolvem mudanças na regulação bioquímica de longa duração do fluxo iônico através da membrana celular, ou seja, alterações no corpo celular e em axônios, não apenas em sinapses. Esses fatos levam a questionar se a memória é desenvolvida por um único processo e sua duração depende do número de seções de treinamento ou se a repetição ativa um diferente tipo de mecanismo de armazenamento.

3.4.2 Mecanismos de Armazenamento de Memória

Nesta altura da pesquisa já foi mencionado, por diversas vezes, que a função das conexões sinápticas é essencial para os mecanismos de aprendizado. Essa função da sinapse em geral é determinada pelo tipo de contato, que por sua vez é determinado pela sua

posição no neurônio. Existem três tipos de contato entre células: *axo-axônico*, *axo-somático* e *axo-dendrítico*, ilustrados na Figura 3.21. Nas figuras do item anterior, pode ser visto que, dentre os três tipos de sinapses, as ligações axo-axônicas estão sempre envolvidas nos caminhos sujeitos aos processos de aprendizado. Essas sinapses apresentam maior importância para o aprendizado pois podem deprimir ou ampliar a liberação de neurotransmissores através da inibição pré-sináptica ou da facilitação pré-sináptica. Isso é realizado através da regulação de cálcio livre (Ca^{++}) no terminal pré-sináptico. De fato, esta é a base para uma variedade de mecanismos que conferem plasticidade em sinapses químicas. Em alguns neurônios a concentração intracelular de Ca^{++} tem influência modulatória em canais iônicos chaveados por tensão.

A maioria dos textos da neurofisiologia analisados, enfatizam o princípio de que o armazenamento de memória não depende de mudanças dinâmicas em um dado circuito fechado de neurônios, mas sim de mudanças plásticas que ocorrem nas células, principalmente em conexões pré-existentes (Kupfermann, 1991). O aprendizado reflexivo não depende de neurônios especializados em memória cuja única função seria a de armazenar informação, mas sim resulta de mudanças em neurônios que são parte integrante de caminhos normais de reflexos.

Essas constatações fazem crer que diferentes tipos de experiência sejam armazenados por diferentes células que tenham outras funções além da função de armazenar informações, como por exemplo nos caminhos de reflexos, etc.

Outro aspecto importante é que as mudanças plásticas não são uma característica de todas as sinapses: *algumas conexões sinápticas do sistema nervoso não mudam sua força de ligação mesmo com ativação repetida*. Por outro lado, nas sinapses envolvidas

com o aprendizado, como aquelas que observamos nas conexões entre neurônios sensores e os neurônios motores e nas conexões com interneurônios, no caso do condicionamento de reflexos, uma pequena quantidade de treinamento pode produzir grandes e duradouras mudanças na força de ligação sináptica.

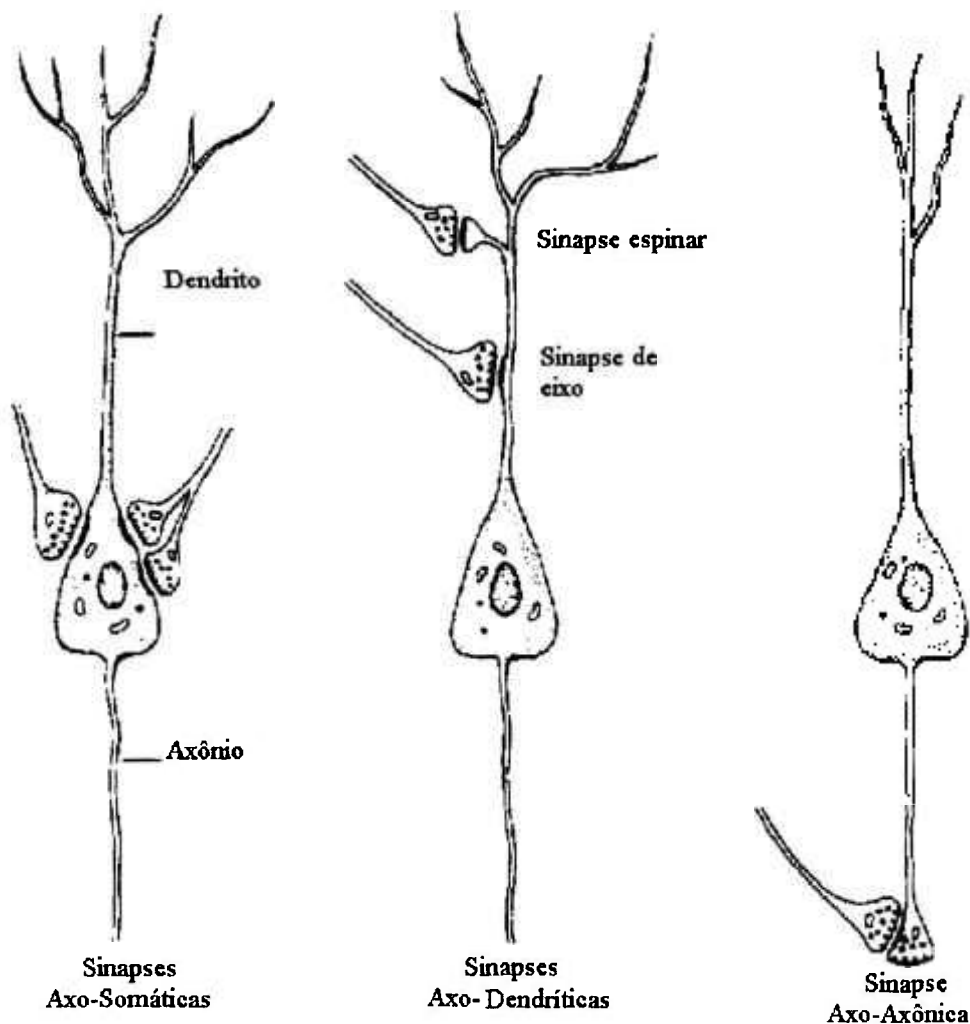


Figura 3.21 - Tipos de Conexões Sinápticas (Kandel e Schwartz, 1991).

Outros tipos de resposta podem ser observados em outros tipos de células. Existem células que respondem a uma excitação constante disparando uma seqüência desacelerada de potenciais de ação, outras que mantêm uma freqüência constante de disparos, e

outras ainda que respondem com uma série crescente de disparos. No processo chamado de *potenciação pós-tetânica*, seguindo a uma grande taxa de excitação do neurônio pré-sináptico, ocorre um aumento sucessivamente mais prolongado na amplitude dos potenciais pós-sinápticos. Esse fortalecimento na força sináptica representa um modo de relembrar eventos passados no neurônio. Em algumas células a frequência de potenciais pós-sinápticos continua a aumentar por minutos ou mesmo horas e esse aumento é seguido por um processo de maior duração chamado de *potenciação de longa duração*, que pode perdurar muitas horas e mesmo dias.

Eric R. Kandel (1991b) discute estudos celulares que indicam que o processo de armazenamento de memória de longa duração parece ser uma extensão graduada dos processos de curta duração. Ele observa que, em primeiro lugar, a memória de longa duração na sensitização é acompanhada por mudanças na força das conexões sinápticas no mesmo local envolvido nos processos de curta duração, no caso do reflexo de contração da guelra da lesma do mar isso ocorre entre os neurônios sensores e motores. Em segundo lugar, tanto nos processos de curta duração quanto nos processos de longa duração, o fortalecimento das ligações sinápticas é devido ao aumento da liberação de transmissor, não se observando mudanças na sensibilidade do receptor pós-sináptico. Em terceiro lugar, a serotonina, um neuro-transmissor modulador que pode produzir facilitação de curta duração após uma única exposição, produz facilitação de longa duração após quatro ou cinco exposições. Finalmente, um mensageiro intracelular secundário chamado cAMP, envolvido na facilitação de curta duração, também produz mudanças de longa duração.

Apesar das similaridades no nível celular, podem ser percebidas diferenças entre os processos de curta duração e os processos de longa duração que surgem no nível

molecular. Enquanto que a facilitação de curta duração envolve a modificação de proteínas pré-existentes, e não é afetada por inibidores de proteína, a facilitação de longa duração não ocorre se houver inibidores, além de requerer a síntese de uma nova proteína. Essa descoberta reforça a idéia da especialização de algumas sinapses decorrente de processos evolucionários pois sugere que genes não envolvidos diretamente com a facilitação de curta duração são requeridos para a facilitação de longa duração. Kandel ainda discute estudos moleculares mostrando que, com repetido treinamento, uma proteína dependente do cAMP age no núcleo dos neurônios sensores ativando reguladores, que por sua vez ativam genes que, produzindo proteínas, causam o crescimento de conexões sinápticas: *os dendritos dos neurônios motores nos animais sensibilizados cresceram para acomodar as entradas sinápticas adicionais.*

Como conclusão desta parte da pesquisa, observa-se que mudanças morfológicas parecem ser a assinatura dos processos de longa duração, pois não ocorrem nos processos de curta duração. E essas mudanças estruturais que ocorrem nos processos de longa duração não se restringem ao crescimento das conexões. A habituação de longa duração provoca uma regressão e mesmo a eliminação de conexões sinápticas, quando o número de terminais por neurônio é drasticamente reduzido.

Com isto fica concluída a seqüência de investigação proposta no final do Capítulo 2. A partir daqui pode ser introduzida a apresentação da seqüência de raciocínios que ligou os aspectos relacionados às oportunidades de inovação suscitadas no Capítulo 2, com a pesquisa na neurofisiologia apresentada resumidamente neste capítulo. Isso é tratado a seguir, mantendo ainda a mesma ordem:

- Arquitetura e Fluxo de Informações;
- Sinalização; e,
- Aprendizado e Mecanismos de Memória.

4 DESENVOLVIMENTO DE UM NOVO CONCEITO DE REDES

Este capítulo é dedicado à exposição da seqüência de idéias que levou à transposição das necessidades apontadas no Capítulo 2 e dos conceitos introduzidos no Capítulo 3, ao novo conceito de uma rede neural artificial para controle.

No início de cada item são apresentadas as principais conclusões resultantes da pesquisa, procurando associar as funções biológicas de uma rede neural biológica dentro dos aspectos descritos resumidamente no Capítulo 3, com os componentes equivalentes da rede neural artificial.

4.1 *Arquitetura e Fluxo de Informações no novo conceito*

O estudo sobre os princípios funcionais e organizacionais dos circuitos neuronais, mostrou que um circuito de controle biológico possui essencialmente dois caminhos separados, um para os comandos de controle, que vêm de um nível hierárquico superior expressando *o desejo* (como exemplo uma posição desejada) e, o segundo para os sinais sensórios, que fornecem as informações *do estado presente*. Foi constatado também que esses circuitos se desenvolveram segundo o *princípio da convergência*, ou seja, com os caminhos do nível de controle superior e dos sistemas sensórios convergindo para as unidades motoras.

O resultado dessas observações é retratado na Figura 4.1, que resume as idéias principais na forma de um circuito com: a) dois caminhos separados para sinais de controle de nível superior e sinais sensórios; b) realimentação de erro (que permite estabelecer, manter ou corrigir postura); e, c) convergência para as unidades motoras.

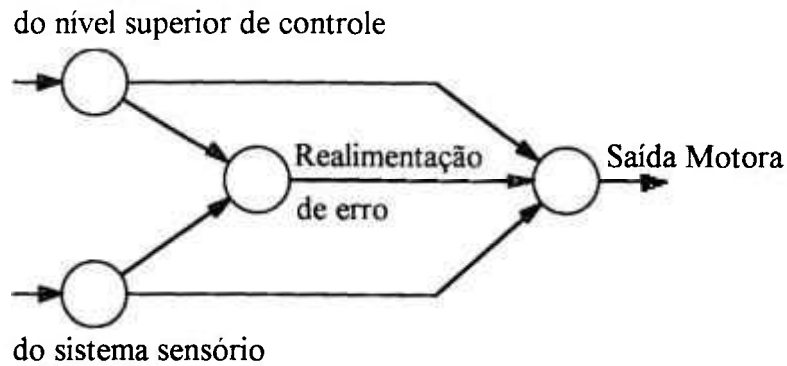


Figura 4.1 - Estrutura típica de um circuito de controle.

4.2 Transmissão de Sinais - “Sinalização”

Este item é dedicado à abordagem dos processos de sinalização, tanto nos aspectos de processo quanto de estrutura, sendo introduzidas as funções de transferência propostas para todos os processos de sinalização neural.

1) *A função de transferência das unidades*: A função de transferência de uma unidade representante de um neurônio é composta pela representação dos processos de integração dos sinais de entrada, da geração de um potencial de ação, e de sua condução a outras células. Olhando para os sistemas biológicos, observa-se que a função de transferência do neurônio é simples e pode ser generalizada, independente de seu tamanho ou forma. Justamente devido a essa peculiaridade biológica, o processo de evolução teve que construir sistemas especialistas para estender o alcance de funções definidas. Um bom exemplo disso pode ser encontrado no trabalho de Akazawa e Kato (1990), que apresentam um modelo para investigar mecanismos neurais de controle de força baseado no “*princípio de tamanho de unidade de motor*.” Uma associação desse exemplo com a hipótese de “*atuação em massa*” (“*common drive hypothesis*” de DeLuca et al., 1982), confirma a idéia de que, além do número de unidades ser importante em termos de robustez, também é essencial para a significação dos sinais. A combinação de “*tamanho*”, “*limiar*” e “*número*”, decorrente do

processo evolucionário, oferece funções de associação muito mais complexas que cada função de transferência isoladamente.

No caso da simulação de redes neurais artificiais, não existem as mesmas restrições de sistemas biológicos, por isso as funções de transferência unitárias podem ser “melhoradas”, reduzindo a necessidade de um grande número de unidades que seria necessário para um dado efeito, aprimorando assim a demanda de processamento e portanto, o tempo de computação. Por exemplo, pode ser utilizada uma única unidade com função de transferência em um domínio real (entre $\pm T_N$) para emular dois circuitos simultaneamente, um pró-ativo e um antagônico, como é o caso dos circuitos que atuam nos músculos de movimento dos membros. A utilização dos limites de domínio até um valor T_N , não unitário, que é o aproveitamento do “*princípio de tamanho de unidade motora*”, evita a duplicação desnecessária de unidades.

Para a implementação dessas idéias foi então escolhida uma função de transferência do tipo *tangente hiperbólica modificada*:

$$O = T_N \tanh (\alpha \sum S) \quad (4.1)$$

onde: O é o sinal de saída; T_N é o “tamanho” da unidade; α é um ganho; e $\sum S$ é a somatória das entradas sinápticas nessa unidade.

Nessa idéia, o tamanho T_N pode assumir qualquer valor conveniente que, por exemplo, melhore a linearidade em uma faixa de interesse ou ainda que amplie ou reduza a relação entrada/saída de sinais, diminuindo a importância dessa unidade.

2) *Modelo de Transmissão Sináptica*: como pôde ser observado em vários pontos da pesquisa, a transmissão sináptica depende de vários processos que se desenvolvem nos terminais nervosos e que são importantes até mesmo para a sobrevivência da célula. As observações colocadas no capítulo anterior trouxe a idéia de melhorar os conceitos de redes neurais artificiais com o uso de “*sinapses múltiplas*”, de modo que seja possível melhorar a capacidade da função de transferência global, aumentando a complexidade conectiva, porém reduzindo a complexidade da rede como um todo pela redução do número total de unidades. Essa idéia é ilustrada na Figura 4.2.




Figura 4.2 - Conceito de sinapses múltiplas.

No capítulo anterior foi visto que no sistema nervoso humano predominam as sinapses químicas, com a sinalização processada por transmissores emitidos pelo terminal pré-sináptico em função do fluxo de potenciais de ação que percorre o axônio. Para representar as características desse processo de um modo eficiente, foram realizados muitos testes antes de se concluir pelo uso da função ilustrada na Figura 4.3, que foi escolhida principalmente pela sua simplicidade e sua característica de “resposta sintonizável” (resposta maior quando mais próximo do limiar $x \rightarrow x^0$):

$$S = \frac{T}{1 + a(x - x^0)^2} \quad (4.2)$$

onde: T é o *tamanho* da sinapse (que definiria a sua “força de transmissão”) e que pode assumir qualquer valor positivo (excitatória) ou negativo (inibitória); a é uma constante escolhida em função do número de sinapses para que a combinação dos sinais de sinapses vizinhas produza funções com variação suave (como será visto a seguir); x é o “valor do sinal” que chega na sinapse; e, x^0 é uma constante no domínio de x , que representa o “limiar” de sintonia: *o ponto máximo de S*.




Figura 4.3 - Exemplo da Função de Transferência Sináptica.

A função da equação (4.2) permite amplificação e resposta seletiva, mantendo uma certa analogia com os processos de formação dos primeiros contatos sinápticos vistos sob a luz da hipótese da ressonância de Paul Weiss (1948). A utilização de múltiplas

funções desse tipo aumenta a capacidade da função de transferência da unidade como um todo e imita o processo estocástico de emissão de transmissor nos contatos sinápticos biológicos. É importante observar que, apesar do aparente aumento de complexidade em relação às redes neurais atuais, a função da equação (4.2) é muito mais simples que uma função sigmóide em termos de tempo de processamento numérico. A composição de um pequeno número dessas funções pode reproduzir qualquer função contínua no seu domínio de uma maneira mais eficiente que uma composição equivalente de funções sigmóide. Mais adiante o uso dessa função de transferência será generalizado. Apenas para ilustrar as características dessa composição, a Figura 4.4 ilustra a emulação de uma função de transferência linear, por meio de um par de sinapses:

$$S = \frac{I}{N} \sum_{n=1}^N \left(\frac{2}{1+0.25(x-2)^2} + \frac{-2}{1+0.25(x+2)^2} \right) \quad (4.3)$$

Na equação (4.3), S é invariante com N , que representa o número de pares de terminais redundantes (conjuntos de sinapses excitatórias + inibitórias) que poderiam ser considerados em uma possível implementação de "hardware". Sem falha em terminais o resultado é independente de N e no caso de qualquer falha de terminais, o efeito no sinal irá depender do número de contatos que falharam e do nível do sinal de entrada.

Como é observado na definição da equação (4.2), a constante a pode ser especificada de modo a evitar efeitos indesejáveis de inflexão entre intervalos consecutivos de limiar, como exemplifica a Figura 4.5. O problema indicado nessa figura pode ser definido considerando as seguintes funções:

$$S_i = \frac{1}{[1 + a(x - x_1^0)^2]} e, \quad (4.4)$$

$$S_2 = \frac{1}{[1 + a(x - x_2^0)^2]} \quad (4.5)$$

A questão que se apresenta então é: *Para que valores de a a função $S = S_1 + S_2$ é sempre crescente entre x_1^0 e x_M , e sempre decrescente entre x_M e x_2^0 ?*




Figura 4.4 - Aproximação de $S = x$.




Figura 4.5 - Inflexões indesejáveis.

Considerando uma condição sem inflexão, mostrada na Figura 4.6 e, considerando a simetria do problema, resolvendo-se o trecho entre x_1^0 e x_M , estará dada a solução também para o trecho entre x_M e x_2^0 . Observe-se ainda que essas condições sempre ocorrem para $x < x_1^0$ e para $x > x_2^0$.

A solução para essa questão é obtida considerando:

$$S = S_1 + S_2 = \frac{1}{[1 + a(x - x_1^0)^2]} + \frac{1}{[1 + a(x - x_2^0)^2]} \quad (4.6)$$

$$\frac{dS}{dx} \Big|_{x_1^0 + \Delta} = \frac{-2a(x - x_1^0)}{[1 + a(x - x_1^0)^2]^2} + \frac{-2a(x - x_2^0)}{[1 + a(x - x_2^0)^2]^2} > 0 \quad (4.7)$$

com $\Delta = x - x_1^0$ e $\Delta x = x_2^0 - x_1^0$ então:

$$\frac{\Delta}{[1+a\Delta^2]^2} + \frac{(\Delta-\Delta x)}{[1+a(\Delta-\Delta x)^2]^2} < 0 \text{ ou} \quad (4.8)$$

$$a < \frac{1}{\Delta^2} \left[\frac{\sqrt{\left(\frac{\Delta x}{\Delta} - 1\right)} - 1}{\left(\frac{\Delta x}{\Delta} - 1\right)^2 - \sqrt{\left(\frac{\Delta x}{\Delta} - 1\right)}} \right] \quad (4.9)$$

fazendo $\Delta = f \Delta x$, com $f < 1/2$, e definindo $b = 1/f - 1$ tem-se:

$$a < \frac{1}{f^2 \Delta x^2} \left[\frac{\sqrt{b} - 1}{b^2 - \sqrt{b}} \right] \quad (4.10)$$

Para obter o valor de a no limite de $f \Rightarrow 1/2$, portanto $b \Rightarrow 1$, deriva-se o numerador e o denominador (L'Hospital) da equação 4.10 obtendo:

$$a < \frac{4}{3\Delta x^2} \quad (4.11)$$




Figura 4.6 - Aproximação sem inflexões indesejáveis.

4.3 *Aprendizado e Mecanismos de Memória*

O conhecimento dos processos de aprendizado mencionados no Capítulo 3, em específico a *habituação*, *sensitização*, *condicionamento clássico* e *prática*, em conjunto com o conhecimento dos mecanismos de armazenamento de memória, foi o precursor de uma série de tentativas que resultaram na concepção de um circuito adequado para implementar o processo de aprendizagem baseado nos mecanismos de *memória reflexiva*.

Dos estudos da neurofisiologia concluiu-se que o papel, na rede artificial, de uma célula facilitadora sobre o contato pré-sináptico da célula em aprendizagem, é promover o aumento ou redução de um termo fonte - *representando algo como a concentração de Ca^{++}* . Esse termo fonte, C , que irá agir nos processos de plasticidade de longa duração, segue um processo cumulativo onde o termo fonte é proporcional a um sinal δ , que representa o sinal de treinamento, e a uma taxa de decaimento λ :

$$\frac{dC}{dt} = T_c \delta - \lambda C \quad (4.12)$$

onde C é a “concentração”, que é gatilho de um outro processo que comanda as mudanças de longa duração; δ é o sinal de saída do terminal facilitador pré-sináptico; λ é uma constante de decaimento; e, T_c é a força de ligação da sinapse facilitadora (que controla a taxa de mudança).

A equação (4.12) faz com que o gatilho da mudança de longa duração (o termo-fonte C) possa crescer proporcionalmente ao sinal de aprendizagem (δ) até um valor de equilíbrio, acelerando ou desacelerando as mudanças na força de ligação. Se o sinal de aprendizado que entra, diminuir até zero, o fator de disparo de mudança também vai a zero,

de acordo com o estabelecido pela constante de decaimento (λ). Isso significa que depois de um período razoável de treinamento, quando o sinal de aprendizado tiver atingido valores insignificantes, não haverá necessidade para mudanças adicionais, fazendo com que o processo seja inerentemente estável.

Para completar essas idéias, ao processo de gatilho ainda é necessário adicionar o processo que efetue as mudanças de longa duração. Para isso ainda foi necessário introduzir um artifício que fizesse com que as mudanças fossem mais acentuadas nas sinapses convenientes, i.e., nas sinapses onde o limiar (x^0) estivesse mais próximo dos valores desejados da entrada, como na hipótese de ressonância de Paul Weiss. Essa característica inovadora, que faz a correta seleção sináptica, é modelada considerando a própria função matemática de transferência das sinapses. Nesse novo modelo idealizado, a taxa de alteração do “tamanho” do contato é uma função do gatilho de mudanças (o termo-fonte C) e da função do terminal de contato:

$$\frac{dT_j}{dt} = \frac{C}{1 + \alpha_s (x_D - x_j^0)^2} \quad (4.13)$$

onde T_j é a força do contato sináptico da j -ésima sinapse; α_s é a constante da função da sinapse facilitadora (diferente da constante da sinapse em treinamento); x_D é o valor do sinal que vem do nível de controle superior (o desejo); e, x_j^0 é o limiar da sinapse em treinamento.

Resumindo, a equação 4.12 pode ser explicada como sendo a equação que emula o processo de acumulação de Ca^{++} dentro de um terminal sináptico, gerando um termo fonte que é o gatilho do termo de mudança de longa duração, e a equação 4.13 gera a taxa de mudança da força de ligação, seletivamente no terminal sináptico sintonizado com o

sinal desejado (segundo a hipótese de ressonância de Paul Weiss): o processo age em cada contato sináptico da unidade alvo mas, com uma taxa de crescimento mais elevada nas sinapses que têm o limiar mais próximo do sinal desejado, ou seja, em que $x_D \Rightarrow x^0$.

Desse modo pode ser estabelecido um modelo de função de transferência para a unidade motora:

$$s_j = \frac{T_j}{1 + \alpha(x_D - x_j^0)^2} \quad (4.14)$$

$$s_k = \frac{T_k}{1 + \alpha(x - x_k^0)^2} \quad (4.15)$$

$$O = T_N \tanh[\alpha(S_\delta + \sum s_j + \sum s_k)] \quad (4.16)$$

O resultado dessa concepção que leva em conta a arquitetura dos circuitos das Figuras 4.1 e 4.2, é representado no circuito da Figura 4.7. Esse circuito utiliza o sinal processado por um interneurônio facilitador, juntamente com o sinal de comando do nível hierárquico superior e o sinal do sistema sensório, todos utilizando conexões axo-axônicas com os terminais pré-sinápticos da unidade de saída (unidade motora), que são os terminais onde as mudanças plásticas devem ser efetuadas. Nessa concepção utiliza-se o sentido (\pm) do sinal δ para decidir se o processo que se desenvolverá nos terminais pré-sinápticos será equivalente a uma facilitação ou a uma inibição pré-sináptica, aumentando ou diminuindo a força de ligação sináptica.




Figura 4.7 - Circuito Esquemático de “*plastificação sináptica*”.

4.4 Conceito de Unidade de Controle Motor

Para completar os conceitos de um controlador, a estrutura típica do circuito de controle da Figura 4.1 ainda requeria a introdução de recursos para atenuação de oscilações. Nos estudos da neurofisiologia foram encontrados, associados aos agrupamentos de células motoras, dados sobre circuitos de interneurônios que possuem características de amortecimento, além é claro das características de amortecimento próprias dos sistemas neuro-musculares. Com essa nova base e a base já comentada no item anterior, a estrutura de controle da Figura 4.1 pôde então ser melhorada e evoluiu para a estrutura representada na Figura 4.8, que define o que chamamos “*unidade de controle motor*”.

Na Figura 4.8 pode ser vista a entrada que define o caminho do nível hierárquico superior, “*o desejo*”, representado por x_D^t , e a entrada do sistema sensorio, “*a condição atual*”, representada por x^t . Desses caminhos derivam linhas laterais que convergem à unidade responsável pela percepção do erro, ε^t . A conexão dessas laterais com a unidade

sensorial do erro é feita por meio de conexões rígidas. A função de transferência dessas conexões é modelada de modo a fazer com que a entrada da condição atual do sistema sensorio tenha sinal oposto ao sinal do desejo, de forma a produzir um sinal de erro: $\varepsilon^t = x_D^{t-\Delta t} - x^{t-\Delta t}$. O esquema de terminais sinápticos múltiplos torna possível a melhoria da confiabilidade pelo aumento no número de terminais, o que pode tornar o sistema mais robusto, se implementado em “hardware”. As equações que correspondem a esses terminais de conexão foram desenvolvidas por experimentação, e foram modeladas de forma semelhante à da equação (4.3):

$$S_{e+} = \frac{I}{N} \left(\frac{2}{1 + 0.25(x - 2)^2} \right) \quad (4.17)$$

$$S_{e-} = \frac{I}{N} \left(\frac{2}{1 + 0.25(x + 2)^2} \right) \quad (4.18)$$

$$S_{i+} = \frac{I}{N} \left(\frac{-2}{1 + 0.25(x + 2)^2} \right) \quad (4.19)$$

$$S_{i-} = \frac{I}{N} \left(\frac{-2}{1 + 0.25(x - 2)^2} \right) \quad (4.20)$$

onde N é o número de redundâncias, que não altera o resultado líquido; o subscrito *e* se refere às sinapses, excitatórias ou inibitórias, que formam porém um conjunto *excitatório* (sinal +); e, o subscrito *i* se refere às sinapses, excitatórias ou inibitórias, que formam porém um conjunto *inibitório* (sinal -).

Para evitar a necessidade de alimentar a rede com as taxas de mudança dos sinais sensorios (derivadas no tempo) foi implementado um artifício para sentir essas taxas internamente à rede. Isso é feito por meio da diferença entre sinais percebidos por unidades

em camadas consecutivas. As unidades responsáveis por essa função são representados na metade inferior da rede representada na Figura 4.8. Essas unidades são acopladas por meio de conexões rígidas como aquelas utilizadas na unidade de erro, definidas pelas equações (4.17) a (4.20). Os sinais de saída dessas unidades, nos vários níveis reproduzem as taxas de mudança dos sinais sensórios, que é equivalente às taxas de mudanças do erro quando o valor desejado é constante. Esses sinais são combinados ao sinal de erro em uma unidade intermediária que faz as conexões com a unidade motora de saída.

Essa combinação de sinais representa a dinâmica do sistema da seguinte maneira:

$$f(\epsilon) = a_0\epsilon + a_1 \frac{d\epsilon}{dt} + a_2 \frac{d^2\epsilon}{dt^2} + \dots \quad (4.21)$$

O coeficiente do termo de erro, a_0 , é implementado por funções sinápticas que possuem constantes ajustadas para produzir uma função de transferência linear:

$$S_{eps} = \frac{1}{N} \left(\frac{T_\epsilon}{1 + 0.25(x - 2)^2} \right) \quad (4.22)$$

$$S_{ips} = \frac{1}{N} \left(\frac{-T_\epsilon}{1 + 0.25(x + 2)^2} \right) \quad (4.23)$$

onde T_ϵ é a força de transmissão da sinapse de erro.

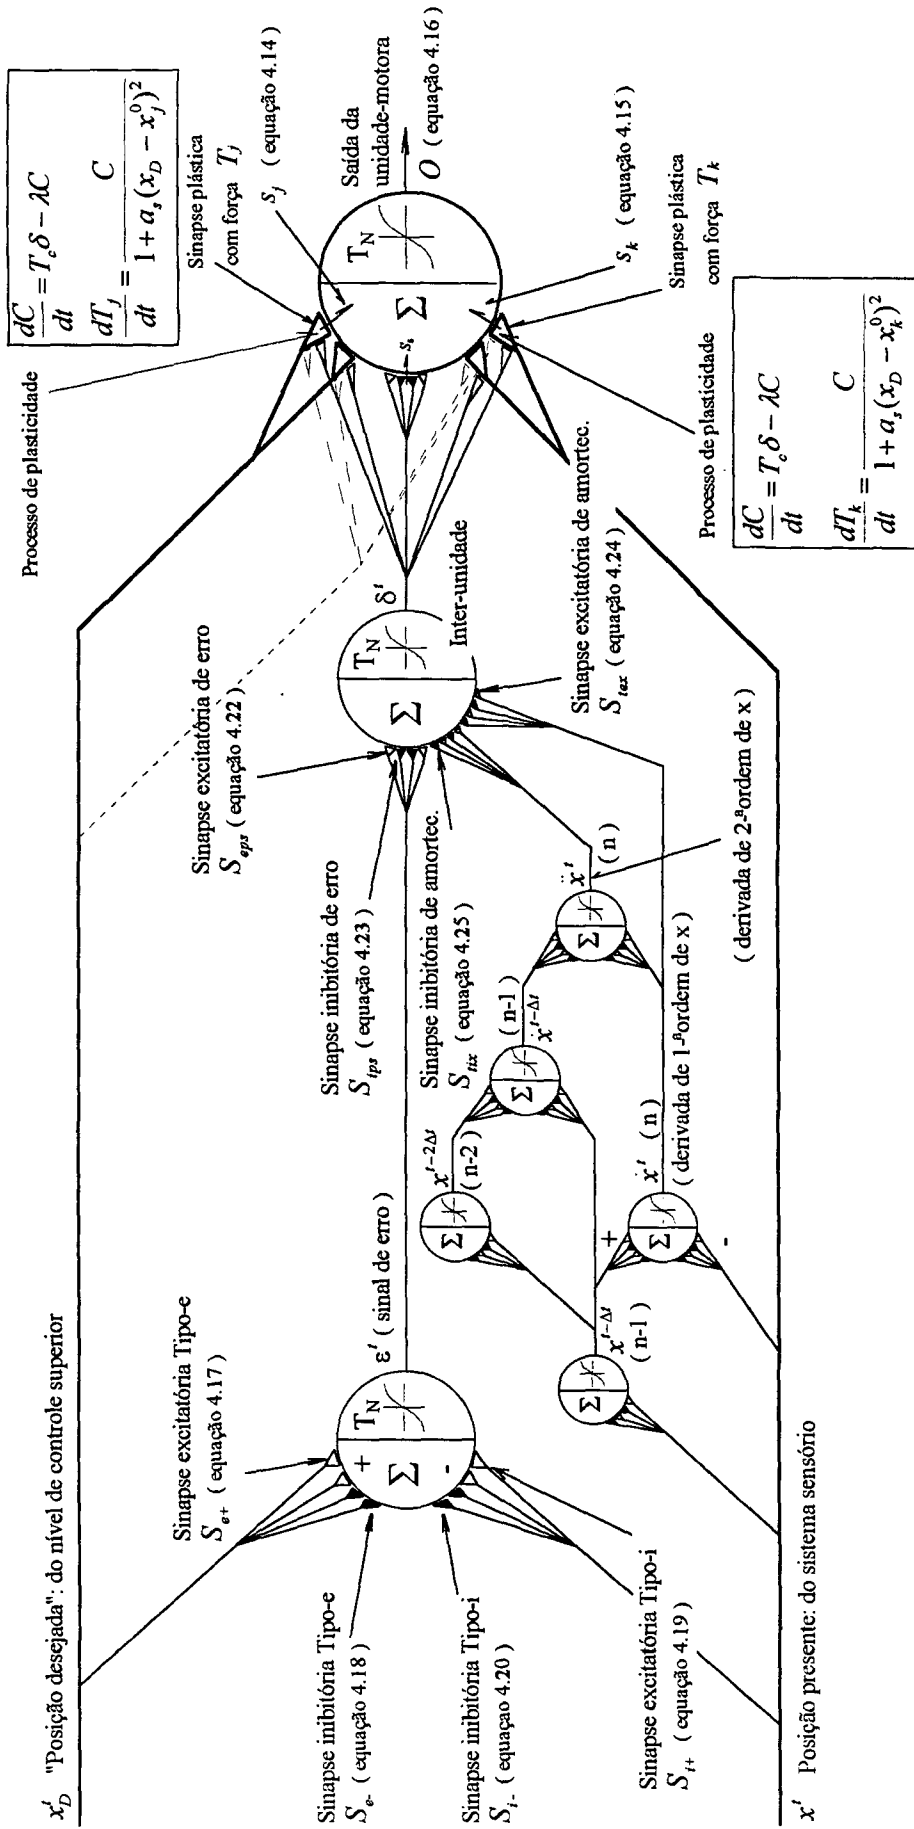


Figura 4.8 - Unidade de Controle Motor.

Por outro lado, os coeficientes das taxas de mudança (a_1, a_2, \dots) foram modelados por sinapses com funções de transferência ajustadas para oferecer características de amortecimento do tipo $x | x |$. Isso já é suficiente para que sejam atenuadas oscilações e seja desenvolvido um processo estável, até mesmo com altas taxas de mudança, típicas na dinâmica de manipuladores. Os coeficientes a_i foram então modelados reproduzindo esse amortecimento, plausível em sistemas biológicos onde se encontra diversos efeitos de amortecimento, principalmente em células musculares:

$$S_{ux} = \frac{I}{N} \left(\frac{T_r}{1 + 11(x-1)^2} \right) \quad (4.24)$$

$$S_{ux} = \frac{I}{N} \left(\frac{-T_r}{1 + 11(x+1)^2} \right) \quad (4.25)$$

onde T_r é a força de transmissão das sinapses de taxas de mudança.

Os sinais sensórios e os sinais do nível de controle superior, juntamente com a combinação dos sinais de taxas e de erro processados por uma unidade intermediária, convergem para a unidade motora cujo sinal produzido (O) será a entrada para os atuadores dos motores. Concluindo, a unidade motora recebe três tipos de sinais: a) informação sensória; b) comandos de nível superior; e, c) uma combinação do erro com as taxas de mudança dos sinais sensórios. Os sinais sensórios e do nível superior são transmitidos por dois conjuntos simétricos de sinapses (em termos de limiar e força de transmissão). São essas sinapses que possuem características plásticas e que serão ajustadas pelo treinamento. Essas sinapses são modeladas por meio das equações 4.14 e 4.15. É importante fazer notar aqui, que no início de um treinamento, essas sinapses plásticas não transmitem nenhum sinal, por não possuírem nenhuma força, i.e., para $t = 0$, $T_j = T_k = 0$. A existência de um sinal de erro

ϵ , logo após o primeiro comando de *desejo*, vai gerar um sinal δ , diferente de zero; que por sua vez vai agir no sentido de aumentar, ou no sentido de diminuir a força de transmissão sináptica, inclusive para valores negativos, de acordo com os processos definidos no item 4.2.

5 MANIPULADOR BI-ARTICULADO NO PLANO

Qualquer proposta de inovação no campo de controle por redes neurais artificiais para sistemas de controle utilizáveis na tecnologia de reatores nucleares, requer muitas avaliações teóricas que comprovem o seu desempenho. Com a finalidade de iniciar essa comprovação foram selecionadas duas aplicações que apresentam problemas complexos com características distintas: 1) o controle de manipuladores robóticos e, 2) o controle de sistemas térmicos de reatores. Ambos são problemas de características não-lineares mas, enquanto o controle de sistemas térmicos apresenta um maior desafio em termos de complexidade de funções, o controle do manipulador se destaca pela sua maior complexidade dinâmica.

Para os testes de desempenho e funcionalidade dos novos conceitos foram desenvolvidos modelos numéricos dos processos físicos e as redes de controle foram simuladas por meio de programas digitais em computador. Neste capítulo são apresentados os modelos e resultados obtidos no controle do manipulador. Os modelos e os resultados do problema referente a sistemas térmicos serão apresentados no Capítulo 6.

5.1 *Modelo da Dinâmica do Manipulador Bi-articulado no Plano*

O manipulador bi-articulado no plano, mostrado na Figura 5.1, caracteriza um sistema não-linear com dois graus de liberdade, cuja dinâmica é modelada em seguida.

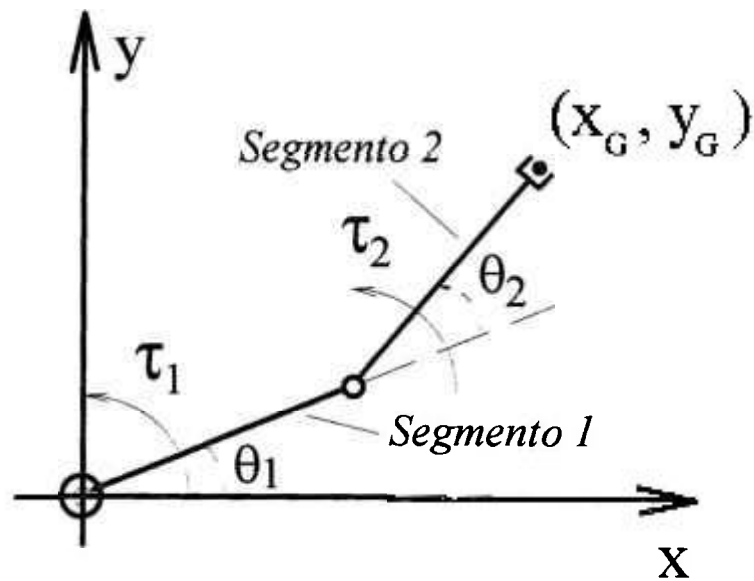


Figura 5.1 - Representação do Problema do Manipulador Bi-articulado.

$$\tau_1 = H_{11} \ddot{\theta}_1 + H_{12} \ddot{\theta}_2 + h_{122} \dot{\theta}_2^2 - h_{121} \dot{\theta}_1 \dot{\theta}_2 - G_1 \quad (5.1)$$

$$\tau_2 = H_{22} \ddot{\theta}_2 + H_{12} \ddot{\theta}_1 + h_{211} \dot{\theta}_1^2 + G_2 \quad (5.2)$$

onde:

$$H_{11} = m_1 l_{c1}^2 + I_1 + [m_2 (l_1^2 + l_{c2}^2 + 2l_1 l_{c2} \cos \theta_2) + I_2] \quad (5.3)$$

$$H_{12} = m_2 l_1 l_{c2} \cos \theta_2 + m_2 l_{c2}^2 + I_2 \quad (5.4)$$

$$H_{22} = m_2 l_{c2}^2 + I_2 \quad (5.5)$$

$$h_{122} = -m_2 l_1 l_{c2} \sin \theta_2 \quad (5.6)$$

$$h_{121} = -2m_2 l_1 l_{c2} \sin \theta_2 \quad (5.7)$$

$$h_{211} = m_2 l_1 l_{c2} \sin \theta_2 \quad (5.8)$$

$$G_1 = m_1 g l_{c1} \cos \theta_1 + m_2 g (l_1 \cos \theta_1 + l_{c2} \cos(\theta_1 + \theta_2)) \quad (5.9)$$

$$G_2 = m_2 g l_{c2} \cos(\theta_1 + \theta_2) \quad (5.10)$$

os subscritos 1 e 2 referem-se respectivamente aos segmentos 1 e 2 do manipulador, cada um com massa m_i , comprimento l_i , distância do centro de massa à articulação l_{ci} , e momento de inércia I_i ; g é a aceleração da gravidade; θ_1 é o ângulo entre o primeiro segmento e o eixo \underline{x} , θ_2 é o ângulo entre o segundo e o primeiro segmentos; e, τ_1 e τ_2 são os torques nas articulações 1 e 2 respectivamente.

A dinâmica de cada motor elétrico acoplado ao manipulador é governada por:

$$J_M \frac{dn}{dt} = \tau_M - \tau - \tau_{PM} \quad (5.11)$$

onde: J_M é o momento polar de inércia do rotor; n é a sua rotação; τ_M é o torque do motor; τ é o torque de carga, calculado por meio de uma das equações (5.1), ou (5.2); e τ_{PM} é o torque de perdas.

Para os propósitos deste trabalho, pode ser considerado um modelo simplificado com resposta imediata do torque do motor:

$$\tau_M = K_T O \quad (5.12)$$

onde K_T é o ganho de torque atuador/motor; e O é a saída do controlador neural acoplado a esse sistema mecânico.

O torque de perdas τ_{PM} é composto de duas partes; as perdas nos mancais, τ_{LB} , e as perdas do motor, τ_{LM} . Um modelo adequado para essas perdas deve considerar tanto o atrito de partida, que em geral é um complicador para a tarefa de controle, quanto os atritos viscosos, comuns em mancais combinados (*axial/radial*) e que em geral facilitam a tarefa de controle. A combinação das perdas associadas a atrito pode ser representada por meio da seguinte relação:

$$\tau_{LB} = K_{LB} \mu \quad (5.13)$$

onde K_{LB} é função do produto da força de carga pelo raio do mancal, ou seja, é função do porte do mancal; e, μ é o fator de atrito que apresenta o comportamento exibido na Figura 5.2.

O fator de atrito foi modelado correlacionando-se dados mecânicos típicos obtidos de Niemann (1950). Por outro lado, a constante K_{LB} depende da existência de um projeto detalhado de mancal, que não existe no problema hipotético deste trabalho. Por isso foi assumido um valor unitário ($K_{LB} = 1,0$), que irá produzir valores pequenos de perdas de atrito.

O torque de perdas no motor, τ_{LM} , pode ser equacionado também na forma de uma perda viscosa, proporcional ao quadrado da rotação do eixo:

$$\tau_{LM} = K_{LM} \omega |\omega| \quad (5.14)$$

onde ω é a velocidade angular ($\dot{\theta}$), e K_{LM} uma constante dependente do tipo de motor.

Desse modo a composição das perdas nos mancais com as perdas nos motores, $|\tau_{PM}| = |\tau_{LB}| + |\tau_{LM}|$, resultou em:

$$|\tau_{PM}| = K_{LB} \left[0.0419\sqrt{|\omega|} + \frac{0.0001419}{|\omega| + 0.007095} - \frac{0.001325}{1 + 20(|\omega| - 0.1)^2} \right] + K_{LM} (\omega)^2 \quad (5.15)$$




Figura 5.2 - Fator de atrito no mancal combinado.

5.2 Acoplamento da Dinâmica do Manipulador com os Controladores

No problema proposto, o manipulador bi-articulado no plano é acionado por dois motores, necessitando por isso de pelo menos duas unidades de controle motor. O modelo mais simples que pode ser idealizado para esse controle tem como sinais de entrada apenas os ângulos θ_1 e θ_2 , desejados e atuais. As velocidades e acelerações angulares ou a

sua combinação podem ser “*sentidas*” por meio das unidades internas. Essa simplificação é interessante nesta fase inicial de demonstração em que se trata o posicionamento da extremidade do manipulador (garra) como um resultado e não como um objetivo. Por isso não se deseja introduzir camadas adicionais de unidades à rede que tenham por função apenas converter as posições de alvo e da garra do manipulador em ângulos desejados e atuais.

É importante mencionar que seria possível constituir um sistema em que houvesse uma rede controladora independente para cada atuador, com todas as combinações possíveis de entradas (isto é, θ_1 , θ_2 , e $\theta_1 + \theta_2$) aplicadas a cada atuador. Nesse caso seria necessário que as redes aprendessem e selecionassem quais entradas são significativas. Porém, seguindo a decisão de se projetar redes especializadas por tarefa, e aproveitando o conhecimento prévio sobre o comportamento do processo físico em si e sobre como os sistemas biológicos lidam com esse tipo de controle, foram consideradas algumas simplificações para otimização do processamento numérico. Considerando que a posição do segundo segmento do manipulador afeta diretamente a carga no primeiro segmento, o atuador do primeiro motor deve receber a soma dos comandos gerados pelos dois controladores ($O_1 + O_2$). Levando em conta que o ângulo θ_2 é relativo à direção do primeiro segmento (Figura 5.1), θ_1 e θ_2 atuais são somados na entrada do segundo controlador ($\theta_1 + \theta_2$).

A Figura 5.3 apresenta um esquema simplificado (sem todos aqueles detalhes dados na Figura 4.8) do acoplamento de duas unidades de controle motor com o manipulador segundo essas considerações. Nessa figura podem ser observadas unidades de entrada que foram adicionadas para proceder à soma dos sinais de entradas. Observa-se que θ_{1D} e θ_{2D} representam os comandos do nível superior (os desejos); O_1 e O_2 são os sinais de saída das unidades de controle motor que alimentam os dois acionadores dos motores D_1 e D_2 ;

IN^E são inter-unidades responsáveis pela percepção do erro, IN^{R1} são inter-unidades responsáveis pela percepção das taxas de variação de primeira ordem, etc. (para simplificar a Figura 5.3, não foram representadas as taxas de segunda ordem); IN^F são as inter-unidades facilitadoras do aprendizado; e, IN^D são inter-unidades que geram sinais atrasados utilizados para a geração dos sinais de taxa de variação.




Figura 5.3 - Acoplamento de duas unidades de controle motor com o manipulador.

5.3 Solução numérica, Parâmetros e dados do sistema

5.3.1 Solução numérica da dinâmica do manipulador

As equações diferenciais que modelam os processos mecânicos do manipulador, representado na Figura 5.4, foram transformadas em equações algébricas e, juntamente com as equações que modelam os controladores neurais, foram resolvidas por meio de um programa computacional (*NEUROSGD.F90*) escrito em FORTRAN 90.

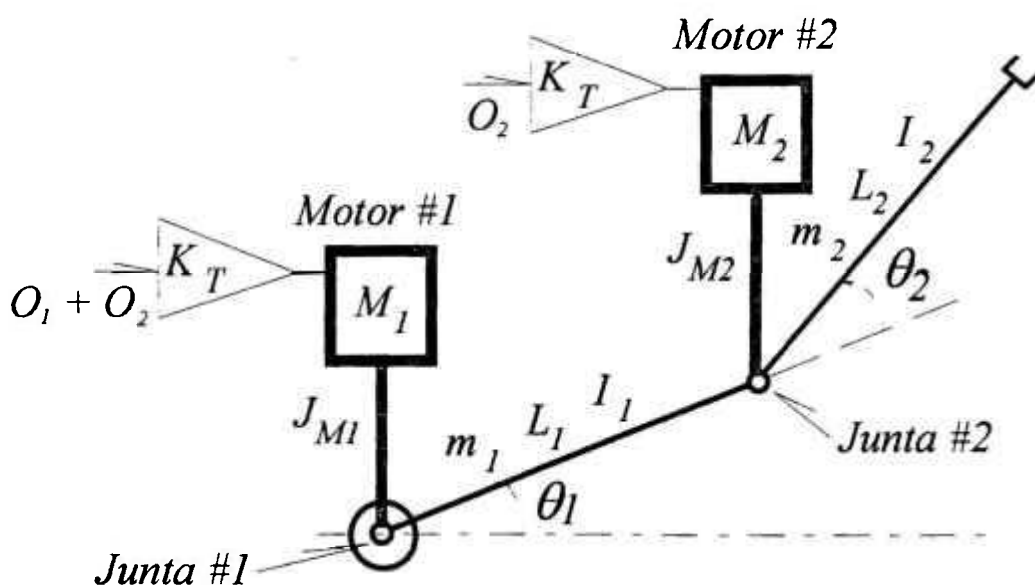


Figura 5.4 - Esquema do Manipulador Bi-articulado.

Com a finalidade exclusiva de reduzir o tempo de processamento numérico, a solução das equações da dinâmica do manipulador foi desenvolvida desacoplando-se a integração das velocidades angulares da integração das acelerações. Isso foi feito após a separação das variáveis do sistema formado pelas equações (5.1) e (5.2):

$$b_1 = [\tau_1 + G_1 - h_{122} \dot{\theta}_2^2 - h_{121} \dot{\theta}_1 \dot{\theta}_2] \quad (5.16)$$

$$b_2 = [\tau_2 + G_2 - h_{211} \dot{\theta}_1^2] \quad (5.17)$$

$$\ddot{\theta}_2 = \left[\frac{b_2 H_{11} - b_1 H_{12}}{H_{22} H_{11} - H_{12}^2} \right] \quad (5.18)$$

$$\dot{\theta}_1 = \left[\frac{b_1 - H_{12} \ddot{\theta}_2}{H_{11}} \right] \quad (5.19)$$

Como o comportamento dinâmico do manipulador modelado não apresenta variações muito acentuadas em termos das velocidades angulares, a integração das mesmas, para obtenção das novas posições, pode ser efetuada por meio do método de Euler Simples:

$$\theta_n^t = \theta_n^{t-\Delta t} + \Delta t \dot{\theta}_n^{t-\Delta t} \quad (5.20)$$

onde n representa o número do segmento do manipulador (1 ou 2).

Por outro lado observou-se que o comportamento das acelerações angulares, $\ddot{\theta}_1^t$ e $\ddot{\theta}_2^t$, poderia requerer intervalos de integração muito pequenos e por isso, para sua integração nas velocidades angulares $\dot{\theta}_1^t$ e $\dot{\theta}_2^t$, foi utilizado o método de Runge-Kutta de 4ª ordem (conforme apresentado em Carnahan, 1967). Esse procedimento permitiu a obtenção de resultados adequados com uma boa economia de processamento numérico.

$$\theta_n^t = \int \ddot{\theta}_n^{t-\Delta t} dt \quad (\text{Runge - Kutta}) \quad (5.21)$$

5.3.2 Implementação dos modelos da rede neural

As equações diferenciais do modelo da rede neural artificial foram integradas utilizando o método de Euler. Sua solução, integrada às demais equações algébricas, é realizada sequencialmente dentro de um módulo do programa de computador conforme o prosseguimento dado a seguir (que considera somente taxas de variação de 2ª ordem):

1ª) a solução para cada uma das unidades motoras é iniciada pela saída da rede, prosseguindo na direção dos pontos de entrada. A modelagem do processamento dos sinais na unidade motora i , no instante t é:

$$(O)_i^t = T_N \tanh[\alpha(\sum S)_i^{t-\Delta t}] \quad (5.22)$$

$$(\sum S)_i^t = \left(S_\varepsilon + \sum_j S_j + \sum_k S_k \right)_i^{t-\Delta t} \quad (5.23)$$

$$(S_\delta)_i^t = \frac{1}{N} \sum_N \left[\frac{2}{1 + 0.25(\delta^{t-\Delta t} - 2)^2} + \frac{-2}{1 + 0.25(\delta^{t-\Delta t} + 2)^2} \right]^{t-\Delta t} \quad (5.24)$$

$$\sum (S_j)_i^t = \sum_j \left[\frac{T_j}{1 + a(x_D - x_j^o)^2} \right]_i^{t-\Delta t} \quad (5.25)$$

$$\sum (S_k)_i^t = \sum_k \left[\frac{T_k}{1 + a(x - x_k^o)^2} \right]_i^{t-\Delta t} \quad (5.26)$$

2ª) Os processos envolvidos na modificação plástica dos terminais sinápticos da unidade motora, compreendendo: a variação do termo-fonte das alterações (C); a sua integra-

ção no tempo; a integração das “forças de ligação” (T_j e T_k), e o cálculo das suas novas taxas de variação no tempo, são modelados como:

$$(C)_i^t = (C)_i^{t-\Delta t} + \Delta t \left(\frac{dC}{dt} \right)_i^{t-\Delta t} \quad (5.27)$$

$$\frac{dC_i^t}{dt} = T_\epsilon \delta^{t-\Delta t} - \lambda C_i^{t-\Delta t} \quad (5.28)$$

$$(T_j)_i^t = (T_j)_i^{t-\Delta t} + \Delta t \left(\frac{dT_j}{dt} \right)_i^{t-\Delta t} \quad (5.29)$$

$$\left(\frac{dT_j}{dt} \right)_i^t = \left[\frac{C}{1 + a_s (x_D - x_j^o)^2} \right]_i^{t-\Delta t} \quad (5.30)$$

$$\left(\frac{dT_k}{dt} \right)_i^t = \left[\frac{C}{1 + a_s (x_D - x_k^o)^2} \right]_i^{t-\Delta t} \quad (5.31)$$

obs.: pela condição de simetria imposta, para cada terminal j há um terminal k de idêntica

força de ligação: $(k = j \rightarrow T_k = T_j)$

3^o) Os processos de transmissão de sinais na inter-unidade facilitadora: a geração do sinal de saída δ ; a recepção sináptica linear do sinal de erro ϵ , e a recepção dos sinais de taxas de variação por meio de contatos com amortecimento do tipo $x|x|$ são representados por:

$$(\delta)_i^t = T_N \tanh[\alpha(E_\delta - E \dot{x} - E \ddot{x})_i^{t-\Delta t}] \quad (5.32)$$

$$(E_{\delta})'_i = \frac{1}{N} \sum_N \left[\frac{T_{\delta}}{1 + 0.25(\delta - 2)^2} + \frac{-T_{\delta}}{1 + 0.25(\delta + 2)^2} \right]_i^{t-\Delta t} \quad (5.33)$$

$$(E_{\dot{x}_n})'_i = \frac{1}{N} \sum_N \left[\frac{Tr_1}{1 + 11(\dot{x}_n - 1)^2} + \frac{-Tr_1}{1 + 11(\dot{x}_n + 1)^2} \right]_i^{t-\Delta t} \quad (5.34)$$

$$(E_{\ddot{x}_n})'_i = \frac{1}{N} \sum_N \left[\frac{Tr_2}{1 + 11(\ddot{x}_n - 1)^2} + \frac{-Tr_2}{1 + 11(\ddot{x}_n + 1)^2} \right]_i^{t-\Delta t} \quad (5.35)$$

onde o índice n se refere à camada do interneurônio, conforme a Figura 4.8.

4^o) Os processos de percepção das taxas de variação (\dot{x} e \ddot{x}) por meio de unidades em camadas consecutivas são representados por:

$$(\dot{x}_n)'_i = \frac{T_N}{\Delta t} \tanh[\alpha(Sx_n + Sx_{n-1})]_i^{t-\Delta t} \quad (5.36)$$

$$(\ddot{x}_n)'_i = \frac{T_N}{\Delta t} \tanh[\alpha(S\dot{x}_n + S\dot{x}_{n-1})]_i^{t-\Delta t} \quad (5.37)$$

$$(Sx_n)'_i = \frac{1}{N} \sum_N \left[\frac{2}{1 + 0.25(x - 2)^2} - \frac{2}{1 + 0.25(x + 2)^2} \right]_i^{t-\Delta t} \quad (5.38)$$

$$(S\dot{x}_{n-1})'_i = \frac{1}{N} \sum_N \left[\frac{-2}{1 + 0.25(\dot{x}_{n-1} - 2)^2} + \frac{+2}{1 + 0.25(\dot{x}_{n-1} + 2)^2} \right]_i^{t-\Delta t} \quad (5.39)$$

$$(S\dot{x}_n)'_i = \frac{1}{N} \sum_N \left[\frac{2}{1 + 0.25(\dot{x}_n - 2)^2} - \frac{-2}{1 + 0.25(\dot{x}_n + 2)^2} \right]_i^{t-\Delta t} \quad (5.40)$$

$$(S \dot{x}_{n-1})'_i = \frac{1}{N} \sum_N \left[\frac{-2}{1+0.25(x_{n-1}-2)^2} + \frac{+2}{1+0.25(x_{n-1}+2)^2} \right]_i^{t-\Delta t} \quad (5.41)$$

$$(\dot{x}_{n-1})'_i = \frac{T_N}{\Delta t} \tanh[\alpha(Sx_{n-1} + Sx_{n-2})]_i^{t-\Delta t} \quad (5.42)$$

$$(S \dot{x}_{n-2})'_i = \frac{1}{N} \sum_N \left[\frac{-2}{1+0.25(x_{n-2}-2)^2} + \frac{+2}{1+0.25(x_{n-2}+2)^2} \right]_i^{t-\Delta t} \quad (5.43)$$

$$(x_{n-1})'_i = \frac{T_N}{\Delta t} \tanh[\alpha(Sx_n)]_i^{t-\Delta t} \quad (5.44)$$

$$(x_{n-2})'_i = \frac{T_N}{\Delta t} \tanh[\alpha(Ex_{n-1})]_i^{t-\Delta t} \quad (5.45)$$

$$(x_{n-1})'_i = \frac{T_N}{\Delta t} \tanh[\alpha(Ex_n)]_i^{t-\Delta t} \quad (5.46)$$

$$(Ex_n)'_i = \frac{1}{N} \sum_N \left[\frac{2}{1+0.25(x-2)^2} + \frac{-2}{1+0.25(x+2)^2} \right]_i^{t-\Delta t} \quad (5.47)$$

$$(Ex_{n-1})'_i = \frac{1}{N} \sum_N \left[\frac{2}{1+0.25(x_{n-1}-2)^2} + \frac{-2}{1+0.25(x_{n-1}+2)^2} \right]_i^{t-\Delta t} \quad (5.48)$$

5^o) A sinalização que gera o sinal de erro ε é modelada por:

$$(\varepsilon)'_i = T_N \tanh[\alpha(Lx_D - Ex_D)]_i^{t-\Delta t} \quad (5.49)$$

$$(Ex_D)'_i = \frac{1}{N} \sum_N \left[\frac{2}{1+0.25(x_D-2)^2} + \frac{-2}{1+0.25(x_D+2)^2} \right]_i^{t-\Delta t} \quad (5.50)$$

$$(F_{x_B})'_i = \frac{1}{N} \sum_N \left[\frac{-2}{1+0.25(x+2)^2} + \frac{+2}{1+0.25(x-2)^2} \right]^{i-\Delta} \quad (5.51)$$

Essa seqüência de equações foi escrita na forma de um programa fonte em FORTRAN 90 e foi produzido um módulo executável utilizando o sistema de desenvolvimento *FORTRAN POWER STATION* (Microsoft Corporation, 1995). As informações necessárias sobre o programa são fornecidas no Apêndice 1.

5.3.3 Parâmetros e Dados Utilizados nos Modelos

A Tabela 5.1 apresenta os parâmetros de simulação do manipulador.

Tabela 5.1 - Características do Manipulador simulado.

Parâmetro	Segmento	
	1	2
Comprimento - L (mm)	707	707
Massa - m (kg)	3,0	2,0
Momento de Inércia - I (kg m ²)	0,041	0,027
Ganho de torque no motor - K_T (Nm)	60	30
Momento de inércia do rotor - J_M (kg m ²)	0,0013	0,0013
Constante de perdas no motor - K_{LM} (eq. 5.15)	25,1	25,1
Constante de atrito dos mancais - K_{LB} (eq. 5.15)	1	1
Demais termos do atrito nos mancais	eq. 5.15	eq. 5.15

As características especificadas para as duas unidades de controle motor da rede neural são mostradas na Tabela 5.2. Observa-se que alguns dos valores dessa tabela foram obtidos teoricamente para atender condições desejadas já discutidas nos itens anteriores, outros, como os “*tamanhos das sinapses*” T_N , T_E , T_r e T_c , constante de ganho α , nú-

mero de terminais jj e kk , e constante λ , foram obtidos tentativamente, não representando porém condições otimizadas.

Tabela 5.2 - Características das unidades de controle motor.

Parâmetro	Valor
“Tamanho” das unidades - T_N (equações 5.22/32/36/37/42/44/45/46/49)	2,1
Constante de ganho das unidades - α (equações 5.22/32/36/37/42/44/45/46/49)	0,5
Constante das sinapses plásticas da unidade motora - a (equações 5.25/26b)	28,8
Número de terminais dos axônios sensórios c/ as unidades motoras - kk	15
Número de terminais dos axônios dos “desejos” c/ as unidades motoras - jj	15
Intervalo entre limiar de terminais consecutivos - $\Delta x = x_{j+1}^0 - x_j^0 = x_{k+1}^0 - x_k^0$	$\frac{1}{6} = 0,1666$
Força de ligação das sinapses de erro - $T\varepsilon$ (equação 5.33)	2,5
Força de ligação das sinapses de taxas - Tr (equações 5.34/35)	0,09
Força de ligação das sinapses facilitadoras - Tc (equação 5.28)	0,1
Constante de decaimento das sinapses plásticas - λ (equação 5.28)	10,0
Constante das sinapses facilitadoras - a_s (equações 5.30/31)	144,0

5.4 Resultados

5.4.1 Treinamento da Rede

O treinamento da rede neural proposta é desenvolvido durante a execução de comandos de ação, ou seja, é um *treinamento não-supervisionado*. No exemplo do manipulador bi-articulado foi montada uma tabela de treinamento onde é apresentada apenas a seqüência de *comandos de posição desejada* (θ_{1D} e θ_{2D}) e a *duração de cada um desses comandos* (tempo real simulado e não tempo de CPU). A Figura 5.5 apresenta a seqüência de comandos de treinamento mostrando que os primeiros comandos conduzem o manipulador no sentido horário, indo da posição de repouso, $\theta = -90^\circ$, até a posição $\theta = -185^\circ$, sempre totalmente estirado. Em seguida o manipulador é conduzido ponto-a-ponto, no sen-

tido anti-horário, até a posição $\theta = +185^\circ$ para logo depois retornar à posição de repouso. Essa seqüência de posições foi apresentada seis vezes à rede em treinamento, variando-se apenas o tempo que era mantido cada comando de posicionamento em cada rodada de treinamento. Na primeira e na segunda apresentação da seqüência de treinamento o tempo por comando foi de *5 segundos*, na terceira e quarta foi de *10 segundos*, e na quinta e sexta vez foi de *20 segundos*, totalizando *70 segundos* de treinamento por ponto.




Figura 5.5 - Seqüência de posições comandadas para o treinamento.

Após as seis rodadas de treinamento sobre o conjunto de dados representado na Figura 5.5, o sistema constituído pelo modelo da rede neural e manipulador foi capaz de atender os comandos de posicionamento com precisão da ordem de milímetros. A força de ligação dos trinta terminais sinápticos plásticos (definida pelos T_j e T_k 's das duas unidades motoras, lembrando que $T_j = T_k$ para $j = k$) cresceu do valor inicial zero para os valores

mostrados na Tabela 5.3 e apresentados graficamente na Figura 5.6. O treinamento foi correspondente a um tempo de 1960 segundos (tempo de processo simulado) e foi realizado consumindo 85 segundos de CPU em um microcomputador PENTIUM 166 MHz, se descontados os tempos de inicialização do programa nas seis sessões.

5.4.2 Testes de desempenho da Rede

Com as forças de ligação sináptica que foram atingidas (Tabela 5.3) o próximo passo foi iniciar uma série de testes para avaliar o desempenho da rede de controle principalmente quanto à sua capacidade de generalização, ou seja, na execução de comandos não presentes na tabela de treinamento. Para essa tarefa foram bloqueados os mecanismos de plasticidade anulando-se a força de ligação das sinapses facilitadoras, $T_c = 0$ na equação (4.12), de modo a impedir novas alterações que pudessem mascarar a avaliação da capacidade de generalização. Foram executados testes sobre todo o domínio possível definido pelo círculo de giro do manipulador, de -180° a $+180^\circ$.

Tabela 5.3 - Forças Sinápticas após treinamento.

Unidade Motora Nº 1	
Limiar	$T_i = T_k$
-1.1666667	-0.0302828
-1.0000000	-0.1318568
-0.8333333	-0.0790918
-0.6666667	-0.0481130
-0.5000000	0.0012962
-0.3333333	0.0476049
-0.1666667	0.0856901
0.0000000	0.0996663
0.1666667	0.0858288
0.3333333	0.0483506
0.5000000	-0.0007666
0.6666667	-0.0485760
0.8333333	-0.0810919
1.0000000	-0.1331862
1.1666670	-0.0309491

Unidade Motora Nº 2	
Limiar	$T_i = T_k$
-1.1666667	-0.0172513
-1.0000000	-0.0745807
-0.8333333	-0.0453549
-0.6666667	-0.0279928
-0.5000000	0.0008637
-0.3333333	0.0276660
-0.1666667	0.0488729
0.0000000	0.0565543
0.1666667	0.0488671
0.3333333	0.0280613
0.5000000	-0.0000332
0.6666667	-0.0277429
0.8333333	-0.0457589
1.0000000	-0.0749680
1.1666670	-0.0174941




Figura 5.6 - Forças Sinápticas após treinamento.

A Figura 5.7 mostra a trajetória seguida pela extremidade do manipulador em um teste no qual foram solicitadas cinco (5) mudanças de posição, cada uma definida por um diferente par de ângulos (*alvos*) solicitados à rede:

- 1) partindo da posição de repouso com o manipulador estirado, ou seja, $\theta_1 = -90^\circ$ e $\theta_2 = 0^\circ$, ir à posição $\theta_1 = 0^\circ$ e $\theta_2 = 0^\circ$,
- 2) partindo da posição anterior, $\theta_1 = 0^\circ$ e $\theta_2 = 0^\circ$, prosseguir para a posição $\theta_1 = 0^\circ$ e $\theta_2 = +90^\circ$,
- 3) partindo da posição anterior, $\theta_1 = 0^\circ$ e $\theta_2 = +90^\circ$, prosseguir para a posição $\theta_1 = +90^\circ$ e $\theta_2 = 0^\circ$,
- 4) partindo da posição anterior, $\theta_1 = +90^\circ$ e $\theta_2 = 0^\circ$, prosseguir para a posição $\theta_1 = +90^\circ$ e $\theta_2 = +90^\circ$, e,
- 5) partindo da posição anterior, $\theta_1 = +90^\circ$ e $\theta_2 = +90^\circ$, prosseguir para a posição $\theta_1 = -90^\circ$ e $\theta_2 = -90^\circ$.

Cada uma dessas condições representa um desejo mantido por seis (6) segundos, que seria o tempo oferecido para o sistema *controle/manipulador* atingir a posição desejada e se estabilizar. Deve ser destacado que nesse teste foram escolhidos dois pontos dentro da tabela de treinamento e três pontos fora desse universo.




Figura 5.7 - Trajetória do manipulador no 1º teste.

Como pode ser observado na Figura 5.7, as trajetórias apresentam uma sinusoidalidade nas proximidades do alvo, características dos efeitos de re-alimentação de erro presente na arquitetura da rede. Outra forma de se analisar os resultados, é observando a variação no tempo da distância a cada alvo, conforme mostrado na Figura 5.8. Nela podem ser observados os cinco (5) *picos* que correspondem aos instantes de mudança de comando. Pode ser ainda observado que, mesmo para pontos distantes mais do que 2000 mm da última posição, a nova posição desejada é rapidamente atingida e com mínimas oscilações, e no geral, não se obteve erros com distância superior a 5 mm.




Figura 5.8 - Evolução da distância da extremidade do manipulador ao alvo.

O mesmo teste pode ainda ser observado pela evolução do erro angular de cada uma das unidades motoras, definido pela diferença em graus entre o ângulo desejado e o ângulo atual, conforme indicado na Figura 5.9. Essa figura confirma as observações feitas com relação aos resultados mostrados na Figura 5.8.

A Figura 5.10 mostra a evolução no tempo do torque nos motores $N. 1$ e $N. 2$. Lembrando que, como não foi prevista nem imposta nenhuma limitação para o torque motor, os mesmos podem atingir o produto das constantes de ganho dos atuadores (K_T), dadas na Tabela 5.1, pelo máximo sinal de controle correspondente, $O_1 + O_2$ para a unidade $N. 1$ e O_2 para a unidade $N. 2$. Os resultados mostraram que o máximo torque no Motor $N. 1$ atingiu o valor máximo de 126 Nm, quando do comando de maior distância entre posição atual e desejada. Esse valor é equivalente ao torque necessário para manter uma massa de 9,0 kg em repouso na posição horizontal com o manipulador totalmente estirado e não de-

veria causar nenhum problema ao sistema mecânico das juntas ou motor. No caso do Motor N. 2, o máximo torque não ultrapassou o valor de 45 Nm. Os resultados em termos do torque motor são interessantes por mostrarem que a estabilização ocorre em aproximadamente três (3) segundos.




Figura 5.9 - Evolução do erro angular dos segmentos do manipulador.

Um outro teste interessante foi realizado exclusivamente para observar o comportamento do movimento do manipulador e sua possível semelhança ao movimento de um braço humano. Fora a observação visual que pode ser feita durante a execução do programa de computador, para registro em papel somente podem ser exibidos “instantâneos” da posição do manipulador em intervalos regulares de tempo. Para isso foi editada a Figura 5.11 que mostra instantâneos do movimento do manipulador, em intervalos de 0,2 segundos, durante a execução do comando de mudança da posição de repouso, $\theta_1 = -90^\circ$ e $\theta_2 = 0^\circ$, para a posição $\theta_1 = 0^\circ$ e $\theta_2 = +90^\circ$. Por essa figura pode ser observado que o movimento do manipulador, controlado pela rede da Figura 5.3 (que não prevê níveis de con-

trole mais elevados do que os que existiriam na medula humana), não é um movimento mecanicamente preciso, se assemelhando ao nosso movimento em busca de um alvo que quase sempre envolve correções nas proximidades do alvo. A extremidade do manipulador ultrapassa ligeiramente o alvo sem “tocá-lo” para em seguida iniciar a aproximação definitiva.




Figura 5.10 - Evolução do torque nos motores.

Uma análise quantitativa desse movimento pode ser feita observando a curva da Figura 5.12 que mostra a evolução da distância ao alvo. No primeiro intervalo de tempo de 1,4 s, indicado na Figura 5.12, a distância ao alvo variou de 2236 mm para 149,4 mm, com uma velocidade média resultante de aproximadamente 1500 mm/s. Nos próximos 1,4 s a distância chegou a 7 mm, resultando na velocidade média de aproximadamente 100 mm/s. Do instante de 2,8 s a 4,2 s a distância variou de 7 mm a 5,2 mm, com a velocidade média de 1,3 mm/s. No último intervalo indicado a velocidade média foi inferior a 0,8 mm/s, chegando praticamente a zero logo em seguida. Esse comportamento pode ser qualitativamente

comparado ao nosso quando procurando atingir um alvo posicionado imediatamente à frente dos olhos.

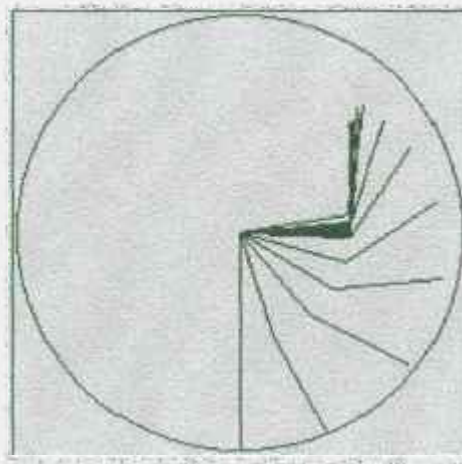


Figura 5.11 - Instantâneos da posição do manipulador.

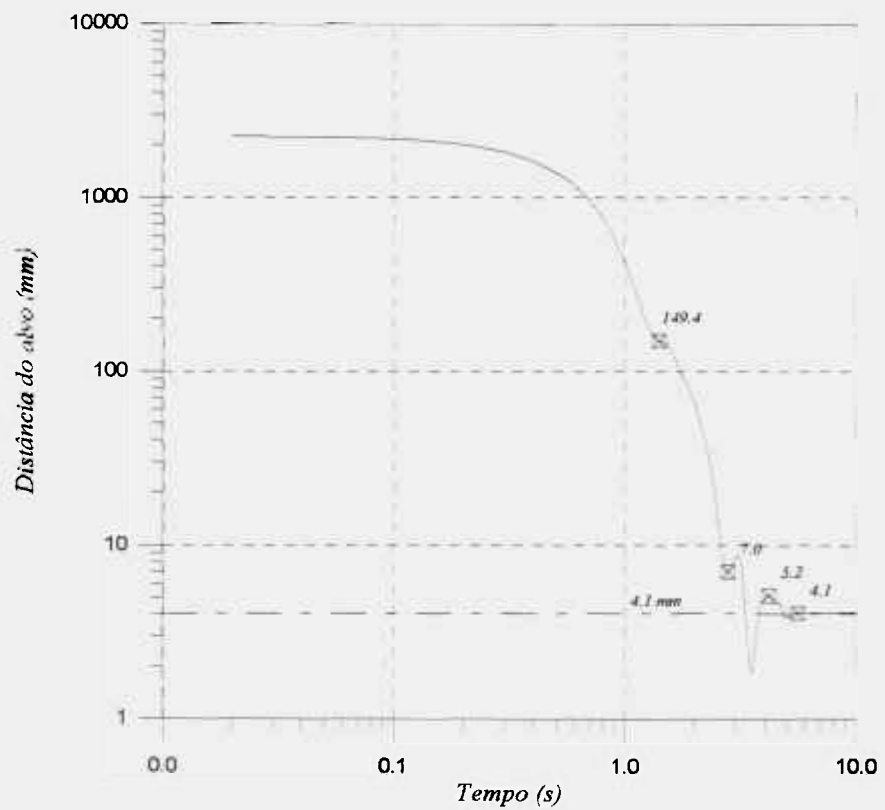


Figura 5.12 - Evolução da distância ao alvo.

5.5 Estabilidade do Processo de Treinamento

Esquemas que utilizam controladores lineares locais independentes para cada motor oferecem resultados adequados no controle de posição em manipuladores robóticos. Os controladores locais tipo Proporcional-Integral-Derivativo (P.I.D.) são adequados para muitas aplicações de controle de posição mas são sujeitos a “overshoot” que pode ser uma condição indesejável em algumas situações. Para esses controladores é facilmente demonstrada a estabilidade do sistema.

Se as taxas de variação de sinais sensórios da rede neural não forem utilizadas, ou mesmo se os principais parâmetros de controle não forem otimizados (que é o caso dos exemplos apresentados), o esquema de rede neural artificial apresentado também sujeita o sistema do manipulador a “overshoot”, como pôde ser observado nos resultados apresentados no item 5.4. Apesar de se ter vislumbrado a possibilidade da eliminação desse efeito por meio de aprimoramentos (inclusão de mais um nível na hierarquia de controle) e otimização da rede (forças de ligação e características das sinapses de amortecimento), foi decidido evitar o investimento sobre esse aspecto neste trabalho pois excederia todos os prazos planejados, uma vez que foi investido muito tempo nas pesquisas da neurofisiologia para os aspectos de inovação. Desse modo este trabalho se focaliza apenas na obtenção de resultados que demonstrem a estabilidade do esquema.

Para essa investigação pode ser considerado um sistema simples com apenas uma articulação e sem sensoreamento interno de taxas de variação, conforme ilustrado na Figura 5.13.

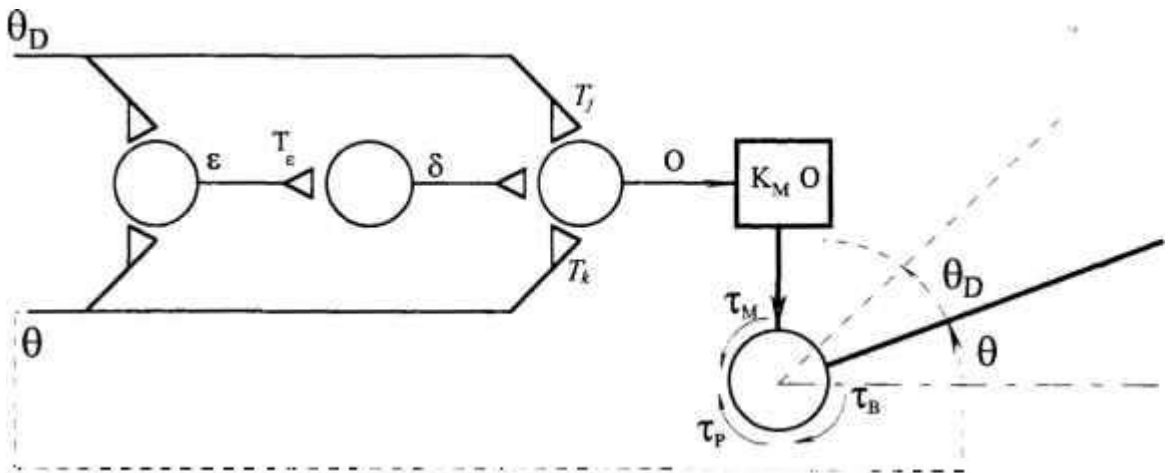


Figura 5.13 - Controlador para manipulador de uma única articulação .

Desprezando a inércia do motor ($J_M = 0$) tem-se que:

$$\tau_M = \tau_B + \tau_P \quad (5.52)$$

onde τ_M é o torque do motor dado por:

$$\tau_M = K_M O \quad (5.53)$$

τ_B o torque do braço dado por:

$$\tau_B = (ml_c^2 + I)\ddot{\theta} + mgl_c \cos\theta \quad (5.54)$$

e τ_P o torque de perdas no motor dado por:

$$\tau_P = K_{LM} \omega |\omega| = K_{LM} \dot{\theta} |\dot{\theta}| \quad (5.55)$$

portanto:

$$K_M O = (ml_c^2 + I)\ddot{\theta} + mgl_c \cos\theta + K_{LM} \dot{\theta} |\dot{\theta}| \quad (5.56)$$

Considerando que a rede utilizada possui apenas três sinapses na unidade motora, a saída O se resume a:

$$O = \frac{T_j}{1 + a(\theta_{Dj} - x_o)^2} + \frac{T_k}{1 + a(\theta - x_o)^2} + \delta \quad (5.57)$$

Se analisadas as equações do Capítulo 4, item 4.2, com $jj = kk = 1$, $T_j = T_k = T$; tem-se que, para $\Delta x \Rightarrow \infty$, $a \Rightarrow 0$ (equação 4.11) e portanto:

$$O = 2T + \delta \quad (5.58)$$

Para simplificar a análise, como mencionado, foi desconsiderado o sensoramento interno da taxa de variação, então:

$$\delta = T_\varepsilon \varepsilon = T_\varepsilon (\theta_D - \theta) \quad (5.59)$$

portanto,

$$O = 2T + T_\varepsilon (\theta_D - \theta) \quad (5.60)$$

Combinando as equações 5.56 e 5.60 obtém-se:

$$T = \frac{1}{2K_M} \left[K_M T_\varepsilon (\theta - \theta_D) + (ml_c^2 + I)\ddot{\theta} + mgl_c \cos\theta + K_{LM} \dot{\theta} |\dot{\theta}| \right] \quad (5.61)$$

O modelo escolhido para os processos de alteração de T , que representa o processo de plasticidade das sinapses, é:

$$\frac{dT}{dt} = \frac{C}{1 + a_s(x - x_0)^2} \quad (5.62)$$

Dadas essas considerações, a primeira análise que deve ser efetuada é a verificação de qual condição estática é atingida após a manutenção de um comando por um longo período de tempo. O máximo da função da equação 5.62 é obtido na condição de máximo valor do termo C . Como a função que comanda o crescimento do termo C , dada pela equação 4.12, segue o comportamento de um processo de variação de concentração, controlado por um termo fonte e uma constante de decaimento, seu máximo é uma função de δ :

$$\left. \frac{dT}{dt} \right|_{\text{máx}} = C_{\text{máx}} = \frac{T_c \delta}{\lambda} = -\frac{T_c T_\varepsilon}{\lambda} (\theta_D - \theta) = -\frac{T_c T_\varepsilon}{\lambda} \varepsilon \quad (5.63)$$

No lado direito dessa equação já foi substituído o valor δ pela equação 5.59. Observa-se portanto, que T irá variar na direção do “gradiente descendente” (direção de redução do erro) enquanto esse erro for diferente de zero (quando $\varepsilon = 0$, $dT/dt = 0$). Dado que podem ser escolhidas constantes adequadas e dado a existência de atrito, pode-se assegurar que o sistema irá estacionar, ou seja, será atingida a condição em que $\dot{\theta} = \ddot{\theta} = 0$ quando então:

$$T = \frac{1}{2K_M} mgl_c \cos \theta_D \quad (5.64)$$

que basicamente representa a condição estática de peso próprio, ou seja, o resultado da manutenção de um comando no treinamento é ajustar T para compensar a componente de peso próprio do braço. Neste caso se a composição das funções sinápticas resultar em um bom

ajuste para as componentes de peso próprio, o erro de posicionamento será pequeno, tanto quanto melhor for esse ajuste. Assim, pode-se concluir que o treinamento pode levar o erro a zero ($\varepsilon \rightarrow 0$).

A segunda análise a ser realizada envolve a comprovação de que o acoplamento da rede com a dinâmica do manipulador, dentro do processo de treinamento, leva à condição estática, ou seja, o manipulador para. Para esta demonstração é conveniente eliminar o termo de atrito da dinâmica do manipulador de modo a comprovar que a própria evolução do treinamento, por meio da alteração da força de ligação T , conduz à condição estática, ou seja, $\dot{\theta} \rightarrow 0$.

Para simplificar o problema, possibilitando sua demonstração analítica, pode-se desconsiderar a inércia e rescrever a equação (5.61):

$$T = \frac{1}{2K_M} [K_M T_e (\theta - \theta_D) + mgl_c \cos \theta] \quad (5.65)$$

derivando no tempo vem:

$$\frac{dT}{dt} = \frac{1}{2} \left[T_e + \frac{mgl_c}{K_M} \sin \theta \right] \dot{\theta} \quad (5.66)$$

$$\text{ou, } \dot{\theta} = \frac{\frac{dT}{dt}}{\frac{1}{2} \left[T_e + \frac{mgl_c}{K_M} \sin \theta \right]} \quad (5.67)$$

considerando que a máxima taxa de variação da força de ligação T é dada pela equação (5.63), tem-se:

$$\dot{\theta} = \frac{\frac{T_c T_e}{\lambda} (\theta - \theta_D)}{\frac{1}{2} \left[T_e + \frac{mgl_c}{K_M} \sin \theta \right]} \quad (5.68)$$

Já foi visto que a força de ligação é continuamente alterada no sentido do gradiente negativo do erro de posição e portanto conduzindo o sistema para a posição desejada. Para as constantes da equação 5.68, podem ser utilizados os mesmos valores considerados na modelagem do manipulador (Tabelas 5.1 e 5.2). Escolhendo um valor desejado qualquer, $\theta_D = 0$ por exemplo, pode ser gerado o gráfico da Figura 5.14, que comprova que a velocidade angular passa pelo *zero* quando é atingido esse valor desejado, ou seja, o sistema *para* e portanto é *estável* mesmo sem o atrito.




Figura 5.14 - Velocidade angular vs. Posição θ para $\theta_D = 0$.

5.6 Comparação com modelos clássicos de redes neurais artificiais

Diferentes conceitos e arquiteturas de redes neurais artificiais já foram utilizados para resolver problemas de controle altamente não-lineares como o problema do manipulador bi-articulado no plano apresentado na seção 5.1. Em geral, essas redes são treinadas segundo algoritmos supervisionados, sendo portanto mais limitadas para essa tarefa do que a nova rede desenvolvida, no entanto, ainda assim é necessária a realização de comparações. Kawato et al (1988) resolvem esse problema com *redes neurais hierárquicas utilizando controle inverso*. Nguyen e Widrow (1990) resolvem problemas desse tipo utilizando uma rede neural de múltiplas camadas para aprender as *características dinâmicas do sistema* e outra rede de múltiplas camadas que *aprende a controlar a rede que emula o processo*. Esta última aproximação requer o desenvolvimento do problema em duas etapas e, segundo os autores, em geral uma rede com duas camadas é capaz de representar o processo emulado. Os autores informam ainda que, no exemplo por eles apresentado, foram necessárias milhares de sessões de treinamento para essas redes, consumindo, conforme relatam, muitas horas de CPU na “Workstation” que dispunham. Handelman, Lane e Gelfand (1990) apresentam uma outra metodologia que integra um *sistema baseado no conhecimento* (“knowledge based system”) a uma rede neural artificial de modo a habilitar o treinamento robótico. Nesse trabalho eles concluem que, apesar das redes neurais terem mostrado eficiência no aprendizado, o treinamento deve ser rigidamente supervisionado pelo operador externo, ou seja, pelo *sistema baseado no conhecimento*.

A Figura 5.15 mostra um esquema tradicionalmente utilizado para a solução de problemas de controle em duas etapas aplicado ao problema do manipulador. Nesse esquema pode ser percebido que a complexidade da rede que emula o processo é até maior

que a da rede de controle. Isso porque o comportamento do processo depende não só dos dois sinais de controle - *um para cada motor* - como também dos sinais de posicionamento e velocidade angular prévios. A rede de processo possui ainda quatro unidades na camada de saída, representando as posições e velocidades angulares presentes que serão utilizados para gerar os sinais de erro necessários para o treinamento. Adicionalmente, para a fase de treinamento é necessária a adoção de um controlador convencional.

Se o objetivo for apenas de comparação de complexidade, esforço de processamento numérico e desempenho, não é necessário seguir esse esquema de duas etapas. Como, de qualquer modo, é necessário um controlador convencional para a fase inicial do treinamento, a rede de processo pode ser totalmente dispensada e pode ser realizado todo o treinamento da rede de controle supervisionado por um controlador convencional (em um esquema parecido com o apresentado por Handelman et al, 1990). Portanto o esquema considerado na Figura 5.16 simplifica a solução e permite a obtenção de resultados para comparação de desempenho, complexidade e tempo de processamento, sem favorecer a nova proposta desenvolvida no presente trabalho.

Para treinar uma rede neural tipo "Feed-Forward", e fazer sua comparação com o novo modelo, foi implementado o algoritmo de retro-propagação em um programa de computador escrito em FORTRAN 90. Esse programa foi baseado na mesma estrutura do programa feito para os testes do novo conceito de rede, utilizando a mesma interface gráfica e rotinas de simulação do manipulador de modo a facilitar a tarefa de comparação de eficiência computacional.

Diversas redes constituídas por diferentes números de camadas e de unidades foram testadas. Todas as redes testadas foram treinadas com o mesmo universo de pontos

utilizado no treinamento da nova rede, conforme Figura 5.5. Para se conhecer o comportamento dessas redes durante o processo de treinamento, foram variados os períodos de tempo dados para treinamento em cada ponto. A taxa de aprendizado também foi variada, entre $0,02 \leq \eta \leq 0,05$, em função de observações de progresso adequado ou de instabilidade.

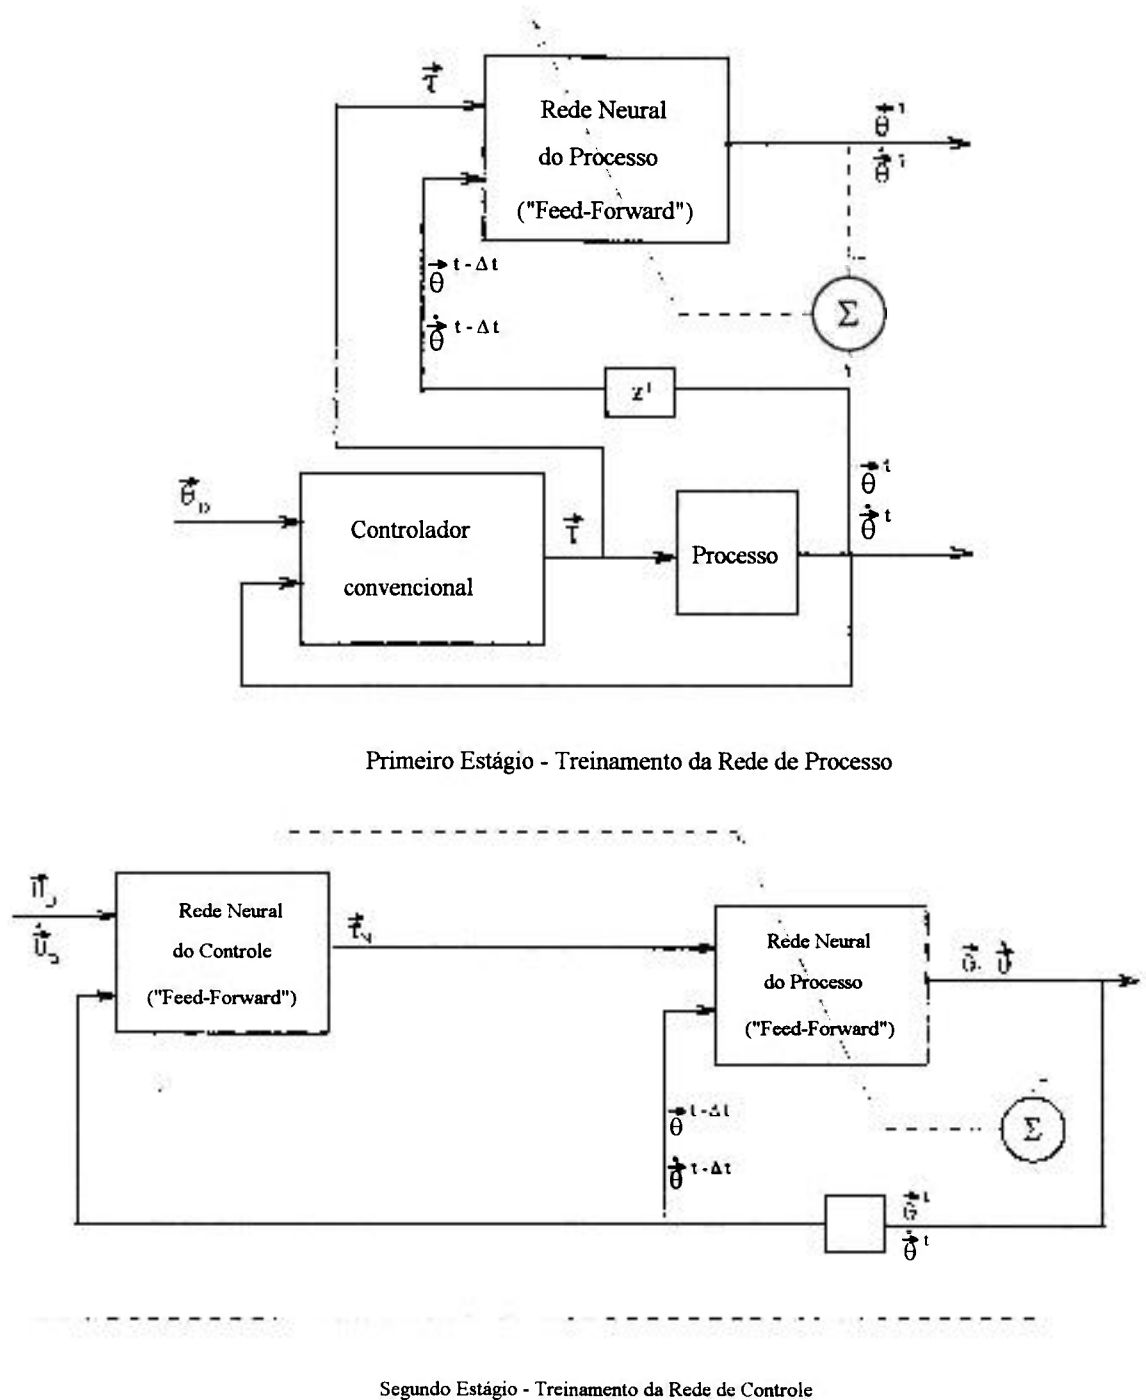


Figura 5.15 - Esquema Típico de Rede "Feed-Forward" com Propagação-para-trás.

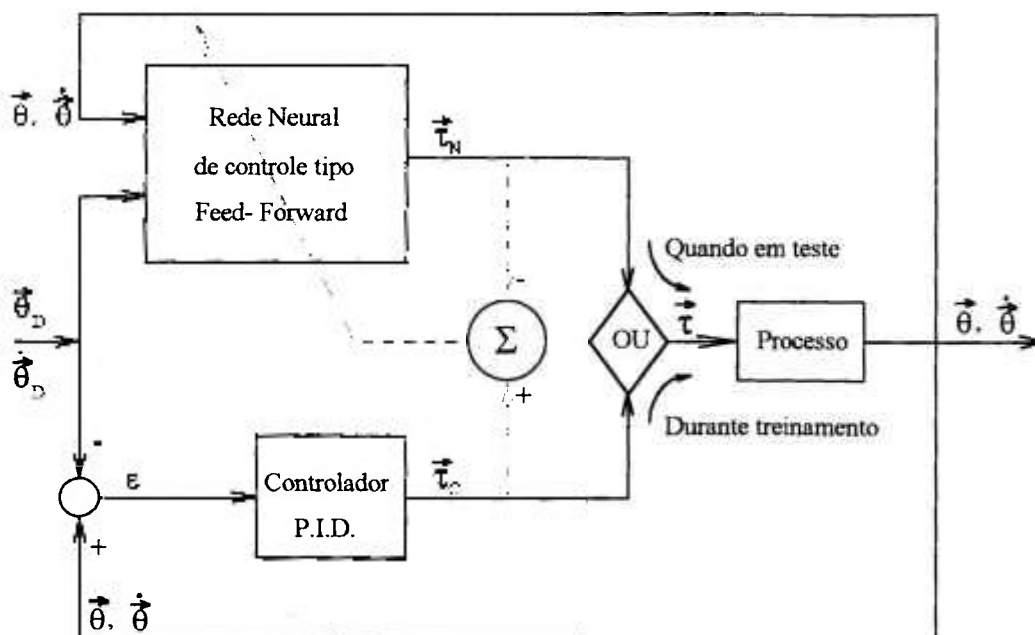


Figura 5.16 - Esquema utilizado com a retro-propagação.

Como era esperado pelas informações de vários autores, a solução não foi trivial. Não foi obtida uma solução adequada na primeira tentativa, que considerou uma rede com duas camadas e dez unidades (neurônios) por camada. Depois de várias tentativas, a rede que melhor se adaptou possuía três camadas. A primeira camada com seis unidades, a segunda com sessenta e a terceira com as duas unidades de saída que geram os sinais para controlar os dois motores. Não foi possível uma parametrização muito extensa pois cada nova tentativa demandava dias de trabalho para se atingir alguma condição “avaliável” (*avaliável* significa que a rede conseguia controlar de algum modo o manipulador). Foram analisadas redes com 10, 20, 30, 40, 60 e 80 unidades na segunda camada. Quantidades inferiores a 60 unidades não mostraram boa capacidade de controle do manipulador em todo o domínio de ângulos. Quantidades superiores a 60 unidades não produziram ganhos sensíveis no desempenho, de modo que o trabalho prosseguiu com uma rede com 60 unidades na segunda camada. É importante observar que somente as sessenta unidades na segunda ca-

mada, mais as seis unidades de entrada e as duas de saída, representam um esforço computacional maior que o exigido pela nova proposta de rede que considerou apenas dezesseis unidades com um total de trinta sinapses plásticas e 188 sinapses rígidas.

A Figura 5.17 apresenta a evolução de um dos pesos sinápticos da rede que pela primeira vez atingiu resultados satisfatórios. Essa figura mostra a convergência de um peso sináptico da última camada e auxilia na descrição do processo de aprendizado. Cada ponto utilizado para construir o gráfico dessa figura corresponde a um alvo comandado ao controlador convencional e não a uma operação de retro-propagação. Durante o treinamento foram dados seis segundos de tempo para o trajeto e parada da extremidade do manipulador em cada alvo comandado. Esse procedimento teve por objetivo permitir que o treinamento consolidasse os sinais estáticos de manutenção do manipulador nas posições. Os padrões da dinâmica do manipulador alimentaram a rede a cada 0,003 s (tempo de integração utilizado na solução das equações da dinâmica). Até a 215ª mudança de alvo (posições desejadas) foi utilizada uma taxa de aprendizado $\eta = 0,02$, modificada a partir daí para $\eta = 0,05$, pois não se observou progresso no treinamento, com a manutenção do peso mostrado na Figura 5.17 próximo ao seu valor inicial. Após essa modificação o treinamento começou a mostrar uma razoável evolução. Após 4088 mudanças de alvo foi constatado que a rede já era capaz de controlar razoavelmente o manipulador nos pontos em que foi realizado o treinamento. Porém verificou-se que ela não era capaz de executar o teste de desempenho do item 5.4.2, Figura 5.7, ou seja, de controlar o manipulador no posicionamento da sua extremidade em pontos interiores ao círculo descrito pela sua trajetória com o braço totalmente esticado. Para remover essa limitação foi necessária uma nova fase de treinamento, exclusivamente sobre os pontos especificados no item 5.4.2. A partir daí a rede foi

capaz de controlar grosseiramente o manipulador nos novos pontos internos ao círculo. Todas essas condições, que simularam aproximadamente 7 horas de tempo real, significaram a apresentação de 8.464.000 padrões à rede, *sendo portanto realizadas também 8.464.000 operações de retro-propagação*, e consumindo mais de três horas e meia (3,5 h) de CPU em um microcomputador com processador PENTIUM de 166 MHz.




Figura 5.17 - Evolução do peso $w(jj, l, l)$ na primeira solução obtida.

Após a obtenção do primeiro sucesso no treinamento da rede, que foi descrito acima, concluiu-se que a taxa de aprendizado deveria ser $\eta = 0,05$ e que seriam necessárias mais de quatro mil processamentos (mudanças de alvo), além de um treinamento adicional sobre os pontos do teste da Figura 5.7 para possibilitar a comparação. Então, para se apresentar resultados de uma condição com a mesma taxa de aprendizado desde o início, o processo de treinamento foi novamente “iniciado do zero”, prosseguindo até 4608 proces-

samentos com a taxa de aprendizado $\eta = 0,05$ e seguindo os pontos da Figura 5.5. De 4609 até 5328 processamentos a rede passou a ser treinada exclusivamente nos pontos do teste do item 5.4.2. Foram repetidas 120 vezes aquelas seis posições desejadas. A evolução do peso $w(jj, l, l)$ durante esse treinamento é mostrada na Figura 5.18.




Figura 5.18 - Evolução do peso $w(jj, l, l)$.

Cabe observar que o acompanhamento do processo de convergência foi feito em geral com base na evolução do peso $w(jj, l, l)$ para não aumentar ainda mais o tempo de processamento com a somatória dos erros quadráticos, uma vez que a *tabela de treinamento*, gerada após a passagem por todas as 28 mudanças de alvo, é constituída por $8.464.000 \times 2$ sinais de torque = 16.928.000 padrões, sendo 112.000 valores a serem processados a cada passagem pelos 28 diferentes alvos. Armazenar esses quase 17 milhões de valores para processamento posterior também não seria adequando. Desse modo a melhor

opção foi observar a evolução de um dado peso e armazenar os erros (não quadráticos) existentes no instante de cada mudança de alvo, para ser possível alguma análise posterior, como mostra a Figura 5.19, que apresenta os erros quadráticos e sua média, calculados posteriormente.




Figura 5.19 - Evolução da somatória do erro quadrático.

É evidente que essa opção deve levar em conta que a evolução de um dado peso pode não ser a mesma na repetição do problema, pois depende dos valores iniciais gerados aleatoriamente. Isso pode ser observado na Figura 5.18 que mostra que a evolução de $w(jj,1,1)$ não foi a mesma obtida na primeira vez: *nem durante a primeira fase nem tampouco durante o treinamento dedicado aos pontos de comparação*. Esse peso convergia para o valor aproximado de 1,7 e a rede nesse instante já conseguia manter algum controle

sobre o manipulador, porém não conseguindo levá-lo para os pontos internos como mostra a Figura 5.20. Apesar disso a evolução do peso sempre foi adequada para acompanhar o processo de convergência.




Figura 5.20 - Trajetória do manipulador após 4608 processamentos.

A partir do processamento 4609, quando da introdução da nova fase de treinamento, se iniciou uma alteração brusca no peso $w(jj, l, l)$. Essa fase prosseguiu por apenas 720 mudanças de alvo e, apesar de ainda não ter atingido convergência, constatou-se que a rede estava apta a controlar razoavelmente o manipulador, como mostrado na Figura 5.21. A Figura 5.22 mostra a evolução da distância da extremidade do manipulador ao alvo^(*) e a Figura 5.23 mostra a evolução dos erros angulares.

^(*) A distância ao alvo só representa um erro de treinamento após a estabilização do manipulador, pois nos instantes próximos à mudanças de comando, essa distância é grande sem contudo representar um erro.




Figura 5.21 - Trajetória do manipulador após 5328 rodadas.




Figura 5.22 - Evolução da distância da extremidade do manipulador ao alvo.




Figura 5.23 - Evolução dos erros angulares.

A comparação dos resultados desse teste com os resultados do novo modelo de rede, apresentados no item 5.4.2, pode ser feita pela análise dos erros de distância mostrados na Figura 5.24. Verifica-se que, enquanto para o novo modelo de rede neural proposto não se obteve erros maiores que 5 mm, para a rede tipo F-F treinada com o método de propagação-para-trás os erros atingiram quase 300 mm. Além dessa comparação observa-se que, apesar de aparentar maior complexidade, a nova rede possui uma arquitetura relativamente simples e de fácil implementação numérica. O novo conceito utiliza um sistema de alteração sináptica dentro dos próprios caminhos de sinalização, e não um algoritmo “externo a esses caminhos” como no caso da propagação-para-trás. A complexidade adicional decorrente do conceito de sinapses múltiplas é compensada pela redução no número de unidades (neurônios) com funções dispendiosas em termos de processamento como a $Tanh()$.




Figura 5.24 - Comparação das distâncias ao alvo entre o novo modelo e a rede F-F.

Na tarefa de aprendizado, o desempenho da nova rede foi aproximadamente 150 vezes mais rápido do que o sistema de propagação-para-trás associado à rede tipo F-F. Foram despendidos apenas 85 segundos de CPU no treinamento da nova rede enquanto foram consumidas 3,5 horas no treinamento da rede com propagação-para-trás.

A capacidade de generalização da nova rede também foi muito superior, justamente por ela ser uma rede projetada e dedicada à tarefa específica de controle do manipulador, ou seja, foi concebida como uma *rede especializada*, aproveitando as características de sistemas biológicos evoluídos e o conhecimento prévio sobre o sistema a ser controlado. Para a nova rede não foi necessário nenhum treinamento adicional para serem atingidos precisamente alvos fora do universo de treinamento. Para a rede tipo F-F foram necessários pelo menos 120 repetições de treinamentos dedicados exclusivamente aos novos alvos.

6 BANCADA DE CIRCULAÇÃO NATURAL

O controle de sistemas térmicos de reatores também representa problemas não-lineares e talvez apresente um maior desafio em termos de complexidade de funções apesar de suas características dinâmicas muito mais lentas que as encontradas no problema do manipulador. Para os testes de desempenho envolvendo sistemas térmicos de reatores foi escolhido um processo de dinâmica complexa, representado por um circuito experimental de circulação natural (Bancada de Circulação Natural - BCN), que simula sistemas de resfriamento de emergência de reatores avançados.

Neste capítulo são apresentados os modelos de simulação da BCN, a validação dos modelos contra resultados experimentais, e os resultados da simulação do controle da BCN utilizando o novo conceito de redes neurais.

A BCN, inaugurada em 4 de março de 1998, foi projetada e montada visando a pesquisa na área de trocadores de calor de sistemas de resfriamento de emergência de reatores avançados; para estudo do controle de sistemas passivos por meio de linhas de desvio da fonte quente; para o estudos de aplicação de redes neurais artificiais em monitoração e diagnóstico; para pesquisas de estratificação térmica; para desenvolvimento de técnicas de análise de ruído; e, para futuro desenvolvimento de controladores por redes neurais. Suas principais características são apresentadas no item a seguir.

6.1 *Características do Circuito de Circulação Natural*

O arranjo mostrado na Figura 6.1 representa o Circuito de Circulação Natural (Baptista F^a, 1996, 1997) que foi concebido nos moldes de um sistema de remoção de calor residual de um reator PWR avançado. O circuito contém um aquecedor elétrico que é a fonte quente do sistema e um trocador de calor, constituído por dois tubulões horizontais com um feixe vertical de tubos imersos em um tanque de água alimentado por gravidade a partir de um reservatório elevado. Além desses componentes e da instrumentação descrita adiante, foi instalada uma bomba para permitir a realização de operações específicas para calibração e determinação das características hidráulicas do sistema.

A tubulação da BCN é de cobre, com 22 mm de diâmetro externo e 0,6 mm de espessura. O circuito foi montado com conexões soldadas e uniões roscadas de ¾ pol. compatíveis com as válvulas, instrumentos e com os bocais dos equipamentos. O aquecedor e todas as tubulações foram isolados termicamente com calhas de lã de vidro de 25 mm de espessura, encamisadas com chapas de alumínio corrugado. Todas as válvulas instaladas nas linhas principais do circuito são do tipo esfera. Para controle da vazão no secundário do trocador de calor foi instalada uma válvula globo e um rotâmetro.

Para o estudo do comportamento de sistemas de circulação natural com linhas de desvio foi instalada uma interligação da “perna-fria” com a “perna-quente” do circuito (esta linha não é utilizada nesta tese). Foi também instalada uma válvula de controle tipo esfera com atuador motorizado e duas ramificações isoladas por meio de válvulas esfera. Na linha principal do circuito, foi instalado um medidor de vazão, tipo magnético, ajus-

tado para a faixa de vazão máxima de 0,1 kg/s e com transmissor com sinal de saída de 4 a 20 mA.




Figura 6.1 - Arranjo do Circuito.

O aquecedor elétrico foi construído em aço inoxidável austenítico e possui três resistências tubulares em “U”. Foi projetado para uma potência máxima de 10 kW mas é controlado para operar somente até 3,3 kW em circulação natural. O trocador de calor foi concebido com base em projetos de aplicação naval e conceitos considerados no projeto do reator AP-600 (Vijuk, 1988), sendo totalmente construído em cobre, com dois tubos de

1 ¼ pol. interligados por 18 tubos de 3/8 pol. imersos em um reservatório com volume de 0,202 m³.

Ao longo do circuito foram instalados 24 termopares, sendo 5 do tipo T de 1,5 mm e 19 do tipo K de 0,5 mm de diâmetro. Para acompanhamento e registro da evolução das temperaturas e da vazão, foi montado um sistema de aquisição de dados baseado em plataforma PC. Foram ainda instaladas 4 tomadas de pressão que permitem determinar os coeficientes de perda de carga de trechos do sistema em condições de circulação forçada, utilizando para isso um manômetro de tubo em “U” invertido.

A variação da potência no aquecedor é feita por meio de um controlador com uma entrada analógica isolada, que pode ser variada entre 0 e 10 V, que atua em um sistema tiristorizado com controle dos disparos feito por um circuito integrado. O controlador de potência pode receber o sinal de controle gerado por uma fonte externa ou advindo de uma saída do sistema de aquisição de dados. A aquisição de dados é feita por meio de uma placa AT-MIO-16E da National Instruments (1995), instalada em um microcomputador PC.

6.2 *Modelo da Dinâmica do Circuito de Circulação Natural*

Para simular os processos térmicos e hidráulicos da BCN, foram desenvolvidos modelos numéricos considerando as convenções de pontos e vazões estabelecidas no fluxograma da Figura 6.2. Nesses modelos foram assumidas as seguintes hipóteses:

- fluido incompressível; e,
- escoamento unidimensional.

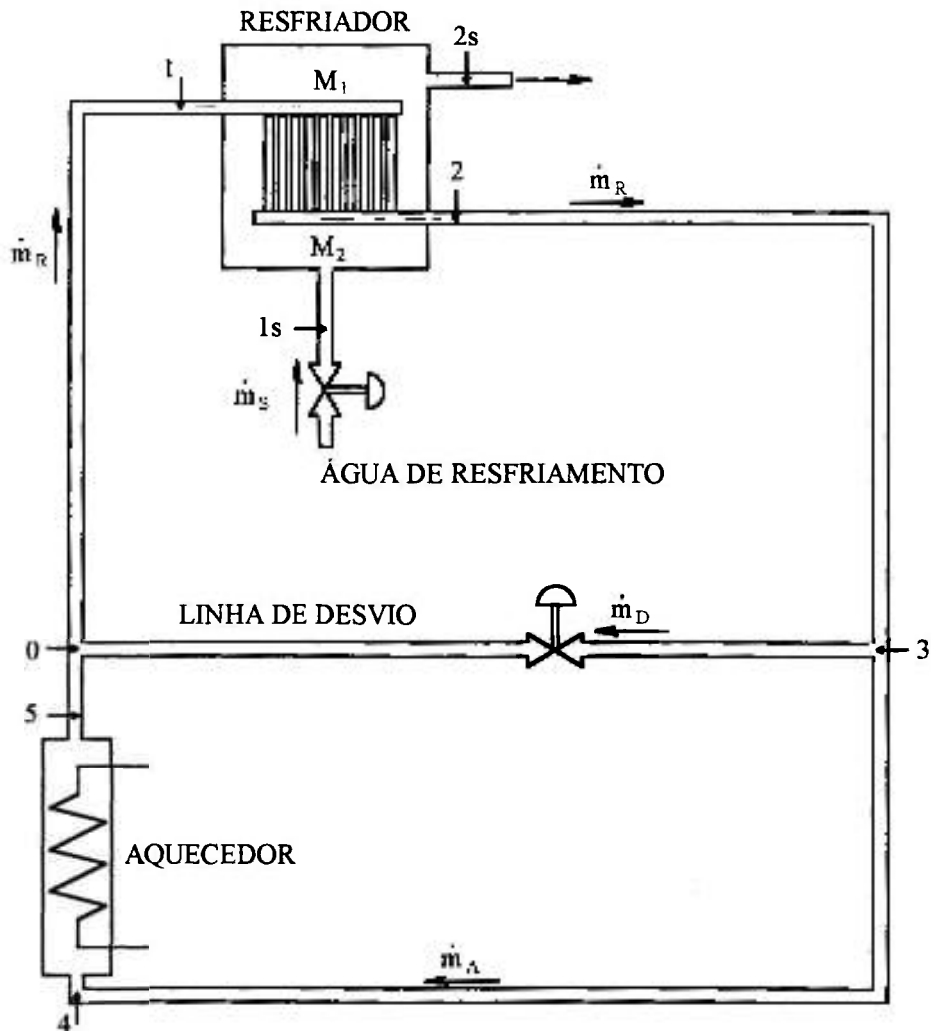


Figura 6.2 - Fluxograma do Modelo do Circuito de Circulação Natural.

Além das hipóteses acima, como os efeitos de aceleração são anulados ao longo do circuito, pois é fechado, os termos de aceleração também foram removidos das equações de conservação da quantidade de movimento. Além disso, para facilitar a solução as equações de continuidade e quantidade de movimento foram desacopladas das equações de energia. As equações são apresentadas a seguir.

6.2.1 Conservação de Massa e Quantidade de Movimento

A equação de conservação de massa é aplicada no ponto "0" da Fig. 6.2:

$$\dot{m}_R = \dot{m}_D + \dot{m}_A \quad (6.1)$$

onde \dot{m}_R é a vazão em massa através do trocador de calor, \dot{m}_D é a vazão em massa pelo trecho de desvio, e \dot{m}_A é a vazão em massa no aquecedor.

As equações de conservação da quantidade de movimento são escritas para cada trecho (entre pontos) da Fig. 6.2:

entre 0 e 1:

$$\frac{\rho_{01} V_{01}}{A^2} \dot{Q}_R = (p_0 - p_1) + \rho_{01} g (z_0 - z_1) - f_{01} \frac{L_{01}}{D} \rho_{01} \frac{Q_R^2}{2A^2} \quad (6.2)$$

onde os novos termos são: ρ (kg/m^3), a densidade média entre 0 e 1; V (m^3), o volume do trecho 0-1; A (m^2), a área de escoamento; \dot{Q}_R (m^3/s^2) é a taxa de variação temporal da vazão volumétrica (dQ/dt); p (N/m^2), a pressão; g (m/s^2) a aceleração da gravidade; z (m) as cotas em relação a um nível qualquer; f o fator de atrito; L (m) o comprimento equivalente do trecho para perda de carga; e, D (m) o diâmetro hidráulico do tubo no trecho.

entre 1 e 2:

$$\frac{\rho_{12} V_{12}}{A^2} \dot{Q}_R = (p_1 - p_2) + \rho_{12} g (z_1 - z_2) - f_{12} \frac{L_{12}}{D} \rho_{12} \frac{Q_R^2}{2A^2} \quad (6.3)$$

entre 2 e 3:

$$\frac{\rho_{23} V_{23}}{A^2} \dot{Q}_R = (p_2 - p_3) + \rho_{23} g (z_2 - z_3) - f_{23} \frac{L_{23}}{D} \rho_{23} \frac{Q_R^2}{2A^2} \quad (6.4)$$

entre 3 e 4:

$$\frac{\rho_{34} V_{34}}{A^2} \dot{Q}_A = (p_3 - p_4) + \rho_{34} g (z_3 - z_4) - f_{34} \frac{L_{34}}{D} \rho_{34} \frac{Q_A^2}{2A^2} \quad (6.5)$$

entre 4 e 5:

$$\frac{\rho_{45} V_{45}}{A^2} \dot{Q}_A = (p_4 - p_5) + \rho_{45} g(z_4 - z_5) - f_{45} \frac{L_{45}}{D} \rho_{45} \frac{Q_A^2}{2A^2} \quad (6.6)$$

entre 5 e 0:

$$\frac{\rho_{50} V_{50}}{A^2} \dot{Q}_A = (p_5 - p_0) + \rho_{50} g(z_5 - z_0) - f_{50} \frac{L_{50}}{D} \rho_{50} \frac{Q_A^2}{2A^2} \quad (6.7)$$

entre 3 e 0:

$$\frac{\rho_{30} V_{30}}{A^2} \dot{Q}_D = (p_3 - p_0) + \rho_{30} g(z_3 - z_0) - f_{30} \frac{L_{30}}{D} \rho_{30} \frac{Q_D^2}{2A^2} \quad (6.8)$$

as vazões volumétricas são definidas por:

$$Q_R = \frac{m_R}{\rho_R} \quad (6.9)$$

$$Q_A = \frac{m_A}{\rho_A} \quad (6.10)$$

$$Q_D = \frac{m_D}{\rho_D} \quad (6.11)$$

onde ρ_R é a densidade média no trocador de calor, ρ_D é a densidade média no trecho de desvio, e ρ_A é a densidade média no aquecedor.

Para simplificar a apresentação podem ser estabelecidos os seguintes agrupamentos de variáveis:

$$\rho V_m = \rho_{30} V_{30} \quad (6.12)$$

$$\rho V_s = (\rho_{23}V_{23} + \rho_{01}V_{01} + \rho_{12}V_{12} + \rho_{30}V_{30}) \quad (6.13)$$

$$\rho V_i = (\rho_{34}V_{34} + \rho_{45}V_{45} + \rho_{50}V_{50} + \rho_{30}V_{30}) \quad (6.14)$$

$$\rho z_s = [\rho_{30}(z_3 - z_0) + \rho_{23}(z_2 - z_3) + \rho_{01}(z_0 - z_1) + \rho_{12}(z_1 - z_2)]gA^2 \quad (6.15)$$

$$\rho z_i = [\rho_{30}(z_0 - z_3) + \rho_{34}(z_3 - z_4) + \rho_{45}(z_4 - z_5) + \rho_{50}(z_5 - z_0)]gA^2 \quad (6.16)$$

$$fL_m = f_{30} \frac{L_{30}}{D} \rho_{30} \quad (6.17)$$

$$fL_s = f_{23} \frac{L_{23}}{D} \rho_{23} + f_{01} \frac{L_{01}}{D} \rho_{01} + f_{12} \frac{L_{12}}{D} \rho_{12} \quad (6.18)$$

$$fL_i = f_{34} \frac{L_{34}}{D} \rho_{34} + f_{45} \frac{L_{45}}{D} \rho_{45} + f_{50} \frac{L_{50}}{D} \rho_{50} \quad (6.19)$$

desse modo pode ser montado e resolvido o sistema de equações, obtendo-se:

$$\begin{aligned} \dot{Q}_R = & \frac{\rho V_m}{(\rho V_s)(\rho V_i) - (\rho V_m)^2} [\rho z_i + fL_m Q_D^2 - fL_i Q_A^2] + \\ & \frac{\rho V_i}{(\rho V_s)(\rho V_i) - (\rho V_m)^2} [\rho z_s - fL_m Q_D^2 - fL_s Q_R^2] \end{aligned} \quad (6.20)$$

$$\dot{Q}_A = \frac{1}{\rho V_i} [\rho V_m \dot{Q}_R + \rho z_i - fL_m Q_D^2 - fL_i Q_A^2] \quad (6.21)$$

$$\dot{Q}_D = \dot{Q}_R - \dot{Q}_A \quad (6.22)$$

6.2.2 Equações de Energia

As equações de conservação de energia no fluido foram escritas considerando-se o modelo da Figura 6.3 e dois tipos de nós, definidos pela forma de acoplamento de regiões consecutivas, conforme ilustrado na Figura 6.4.




Figura 6.3 - Discretização para Energia no Fluido.

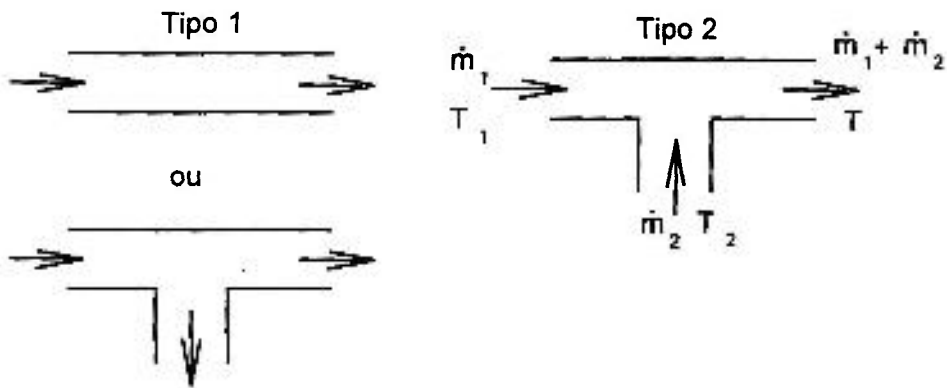


Figura 6.4 - Tipos de "nós".

A equação geral de energia para o fluido, no modelo unidimensional é:

$$\rho A_i c_p \frac{\partial T_i}{\partial t} = -\dot{m} c_p \frac{\partial T_i}{\partial s} - P q'' \quad (6.23)$$

onde ρ (kg/m^3) é a densidade média no volume; A_i (m^2) é a área de escoamento no volume i ; c_p ($\text{J/kg}^\circ\text{C}$) é o calor específico a pressão constante da água; T ($^\circ\text{C}$) a temperatura; \dot{m} (kg/s) a vazão em massa; s (m) define a dimensão linear (x) na direção do escoamento P (m) o perímetro da seção transversal; e q'' (W/m^2) é o fluxo de calor transferido na direção do perímetro P .

Para regiões iniciando com nós do *tipo 1*, a equação (6.23) é aplicada diretamente, fazendo-se a aproximação pelo método da "célula doante". Para regiões com nós

do tipo 2, a equação (6.23) é modificada, ainda considerando o método da "célula doante" e com os termos definidos na Figura 6.4:

$$\rho V_i c_p \frac{\partial T_i}{\partial t} = \dot{m}_1 c_p (T_1 - T_i) + \dot{m}_2 c_p (T_2 - T_i) - P q'' \quad (6.24)$$

6.2.3 Modelo para o trocador de calor

Para o modelo do trocador de calor foi considerada a divisão de volumes da Figura 6.5, acoplados conforme o esquema da Figura 6.6.




Figura 6.5 - Esquema para o Modelo do Trocador de Calor.

Energia no Primário do Trocador de Calor:

$$\rho_{r,i} V_{p,r,i} c_p \frac{\partial T_{p,r,i}}{\partial t} = -\dot{m}_p c_p \Delta s \frac{\partial T_{p,r,i}}{\partial s} - A_{p,r,i} q_{p,r,i}'' \quad (6.25)$$

onde as novas definições são os subscritos r que define a região e i que define o volume; a letra p para especificar que é do lado primário; e a dimensão linear Δs (m) definindo o tamanho do volume.




Figura 6.6 - Detalhamento de regiões no Trocador de Calor.

Energia no Secundário do Trocador de Calor:

$$\rho_{r,i} V_{s,r,i} c_p \frac{\partial T_{s,r,i}}{\partial t} = -\dot{m}_s c_p \Delta s \frac{\partial T_{s,r,i}}{\partial s} - A_{s,r,i} q_s''_{r,i} \quad (6.26)$$

onde a letra s especifica que é do lado secundário.

Energia no Metal dos Tubos do Trocador de Calor:

$$\rho_M V_{M,r,i} c_M \frac{\partial T_{M,r,i}}{\partial t} = A_{p,r,i} q_p''_{r,i} + A_{s,r,i} q_s''_{r,i} \quad (6.27)$$

onde a letra M especifica que é do metal e,

$$q_p''_{r,i} = h_{p,r,i} (T_{p,r,i} - T_{M,r,i}) \quad (6.28)$$

$$q_s''_{r,i} = h_{s,r,i} (T_{s,r,i} - T_{M,r,i}) \quad (6.29)$$

onde h_p e h_s são os coeficientes de transferência de calor por convecção no trocador de calor, que serão obtidos experimentalmente.

6.2.4 Modelo para válvula de regulação de água de resfriamento

Para simular o comportamento da válvula de regulação da água de resfriamento foi considerado um modelo genérico que relaciona a vazão com o C_v da válvula. Foi considerada pressão a montante constante, ou seja, reservatório elevado sem variação de nível. Para o C_v foi assumido o comportamento dependente da abertura ilustrado na Figura 6.7 com a constante obtida por meio de uma medida experimental.

$$Q = \Delta p C_v = k C_v \quad (6.30)$$

$$C_v = (2.7 A e^{-A}) C_{v_{máx}} \quad (6.31)$$




Figura 6.7 - Modelo para o C_v da válvula.

6.3 *Acoplamento da Dinâmica da Bancada com a Rede Neural*

Para a realização dos testes do novo conceito de rede neural artificial no controle da BCN, foi considerado o problema de controlar a temperatura em um ponto qualquer da bancada atuando somente na potência do aquecedor. Esse problema foi cuidadosamente analisado dentro da filosofia de se projetar redes especializadas, concluindo-se que *a temperatura e a vazão da água de resfriamento são perturbações ao processo, e por isso devem ser acompanhadas pela rede neural, produzindo correções ao sinal de controle de potência*. Essa conclusão estabeleceu a necessidade de se procurar novos recursos para tornar a rede robusta a perturbações.

Para atender a essa nova demanda foi idealizado um modelo que tem como sinais de entrada a temperatura desejada e os sinais do sistema sensório definidos pela medida da temperatura a ser controlada, pela temperatura medida na entrada do trocador de calor e pela abertura (posição) da válvula de regulagem da água de resfriamento. A rede que representa esse modelo é constituída por uma unidade de controle motor completa, exatamente como a definida no Capítulo 4, ligada em paralelo a dois ramos adicionais do sistema sensório. Em cada um desses ramos é adicionado apenas um conjunto de sinapses com características plásticas. O sinal δ , composto pela combinação do erro com a taxa de variação da variável de controle medida (no caso a temperatura desejada), é utilizado no processo de alteração sináptica desses conjuntos de sinapses plásticas. Os sinais gerados pelas perturbações (saídas de cada uma das unidades) são utilizados na alteração de ganhos (amplificadores) do sinal principal, modificando a saída da unidade motora (O) e gerando o sinal de controle (Sc):

$$Sc = (O_1)(O_2)(O) \quad (6.32)$$

onde Sc é o sinal de controle e O , O_1 e O_2 são as saídas das unidades motoras da Figura 6.8.

A Figura 6.8 mostra ainda que a rede considera apenas a primeira ordem de variação do erro (1ª derivada), em razão da lentidão dos processos termo-hidráulicos envolvidos na circulação natural que não requerem nada além disso. Essa nova estrutura ilustra bem como podem ser combinados os novos conceitos para se desenvolver novas arquiteturas, específicas para cada tipo de problema de controle, neste caso exemplificando a introdução de variáveis que influenciam o sinal de controle.

6.4 *Solução numérica, Parâmetros e dados do sistema*

6.4.1 *Solução numérica da dinâmica da Bancada*

As equações que modelam os processos térmicos e hidráulicos da BCN, em conjunto com as equações que modelam os controladores neurais, foram resolvidas por meio do programa de computador *BANCADA.F90*, cujas principais características são descritas no Apêndice 2.

A bancada foi dividida nas 14 regiões mostradas na Figura 6.10. A solução da dinâmica dos processos seguiu um método explícito, detalhado a seguir. Foram resolvidas primeiramente as equações de energia (utilizando as vazões do intervalo de integração anterior) e posteriormente o sistema de equações de conservação da quantidade de movimento.

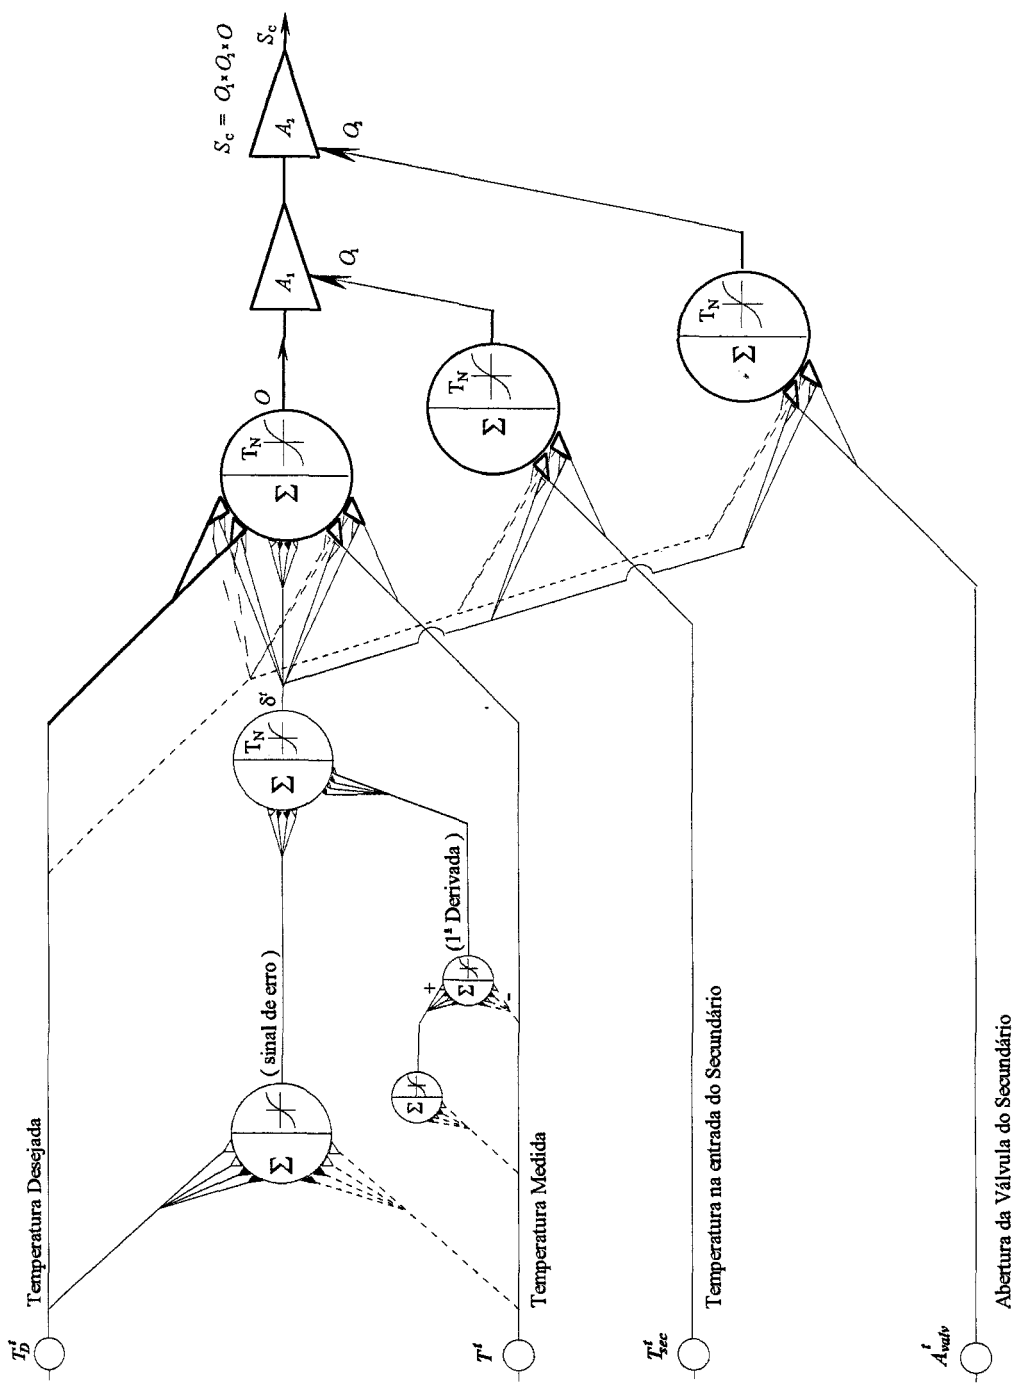


Figura 6.8 - Unidade de controle com dois sinais adicionais do sistema sensorio.

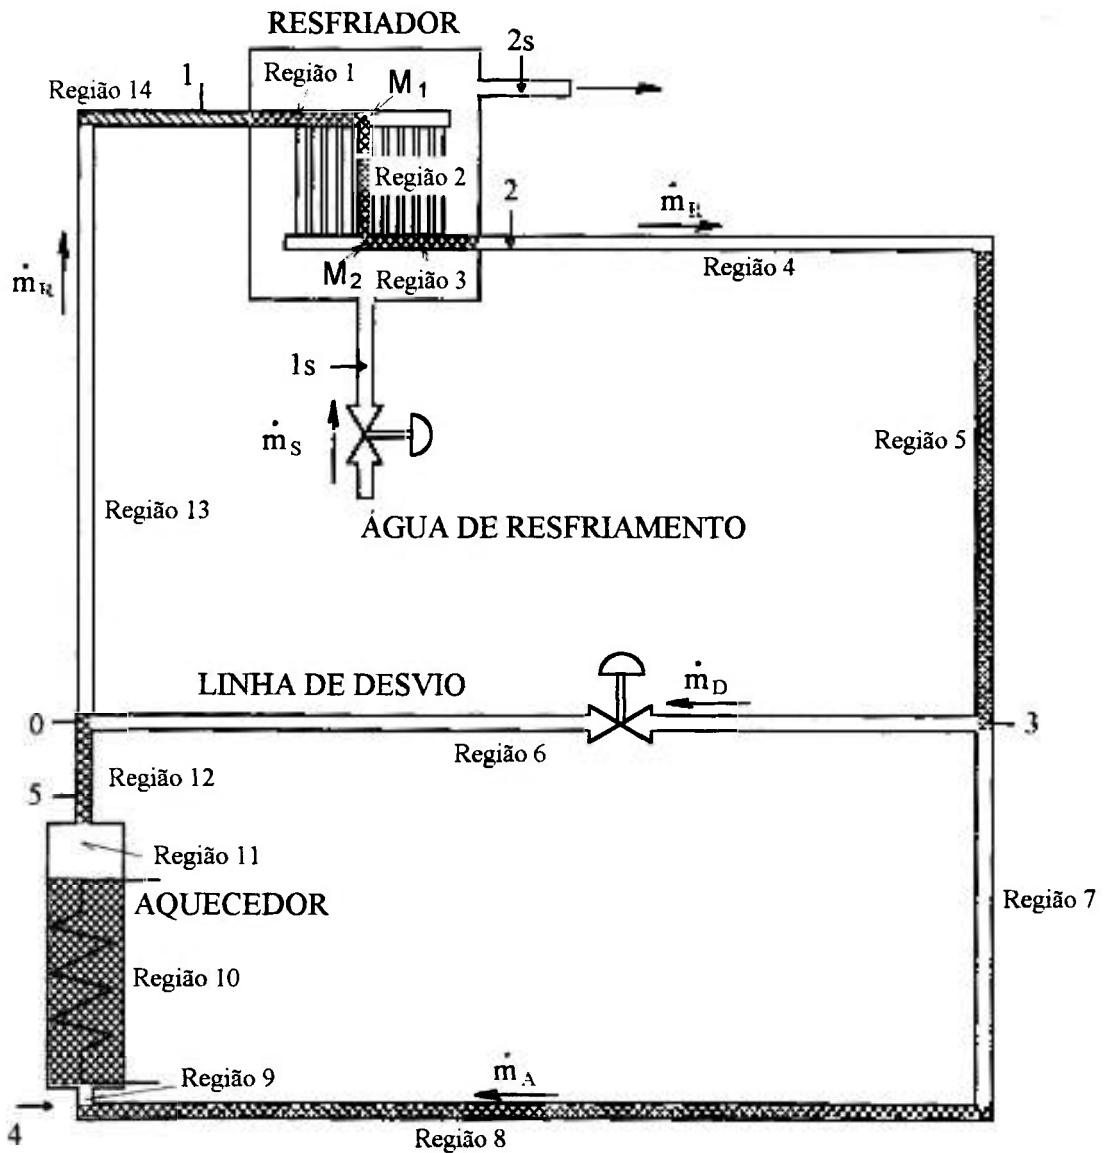


Figura 6.10 - Definição das Regiões modeladas.

Equações de Energia

A solução das equações de energia se inicia no trocador de calor, na região de entrada da água do primário, definida por *Região 1*. A seqüência na solução das equações, com base na divisão de regiões e volumes das Figuras 6.5, 6.6 e 6.10, é detalhada a seguir. Nessa solução j é relacionado à discretização de volumes no secundário do trocador

de calor, dividido em jj volumes conforme Figura 6.5, e i é relacionado à discretização interna de cada região, divididas em $ii(r)$ volumes.

A - Lado Externo dos tubos e tubulações e, partes metálicas

T.C. - $r = 1 \quad j = 3 \quad i = 1 \rightarrow ii(r = 1)$

$$q_s''_{1,i} = h s_1 (T s_j - T_{M_{1,i}}) \quad (6.33)$$

$$q_p''_{1,i} = h p_1 (T p_{1,i} - T_{M_{1,i}}) \quad (6.34)$$

$$\frac{\partial T_{M_{1,i}}}{\partial t} = \frac{1}{\rho_M V_{M_{1,i}} c_M} [A p_{1,i} q_p''_{1,i} + A s_{1,i} q_s''_{1,i}] \quad (6.35)$$

$$\delta q_{s1} = \sum_i [q_s''_{1,i}] \quad (6.36)$$

$$\frac{\partial T s_j}{\partial t} = \frac{Q_s}{V s_j} [T s_{j-1} - T s_j] - \frac{\delta q_{s1}}{\rho_j V s_j c_p} \quad (6.37)$$

onde Q_s é a vazão no secundário obtida conforme equações (6.30) e (6.31) (os coeficientes de transferência de calor são estimados experimentalmente, como será discutido mais adiante).

T.C. - $r = 2 \quad j = jj - 1 \rightarrow 2 \quad i = 1 \rightarrow ii(r = 2)$

$$q_s''_{2,i} = h s_2 (T s_j - T_{M_{2,i}}) \quad (6.38)$$

$$q_p''_{2,i} = h p_2 (T p_{2,i} - T_{M_{2,i}}) \quad (6.39)$$

$$\frac{\partial T_{M_{2,i}}}{\partial t} = \frac{1}{\rho_M V_{M_{2,j}} c_M} [Ap_{2,i} q_p''_{2,i} + As_{2,i} q_s''_{2,i}] \quad (6.40)$$

$$\frac{\partial Ts_j}{\partial t} = \frac{Q_s}{Vs_j} [Ts_{j-1} - Ts_j] - \frac{As_{2,i} q_s''_{2,i}}{\rho_j Vs_j c_p} \quad (6.41)$$

T.C. - $r=3 \quad j=1 \quad i=1 \rightarrow ii(r=3)$

$$q_s''_{3,i} = hs_3 (Ts_j - T_{M_{3,i}}) \quad (6.42)$$

$$q_p''_{3,i} = hp_3 (Tp_{3,i} - T_{M_{3,i}}) \quad (6.43)$$

$$\frac{\partial T_{M_{3,i}}}{\partial t} = \frac{1}{\rho_M V_{M_{3,i}} c_M} [Ap_{3,i} q_p''_{3,i} + As_{3,i} q_s''_{3,i}] \quad (6.44)$$

$$\delta q_{s3} = \sum_i [q_s''_{3,i}] \quad (6.45)$$

$$\frac{\partial Ts_j}{\partial t} = \frac{Q_s}{Vs_j} [Ts_e - Ts_j] - \frac{\delta q_{s3}}{\rho_j Vs_j c_p} \quad (6.46)$$

Loop - Região 4 em diante: $r \geq 4 \quad i=1 \rightarrow ii(r)$

$$q_s''_{r,i} = U_{isol} (T_{amb} - T_{M_{r,i}}) \quad (6.47)$$

$$q_p''_{r,i} = hp_r (Tp_{r,i} - T_{M_{r,i}}) \quad (6.48)$$

$$\frac{\partial T_{M_{r,i}}}{\partial t} = \frac{1}{\rho_M V_{M_{r,i}} c_M} [Ap_{r,i} q_p''_{r,i} + As_{r,i} q_s''_{r,i}] \quad (6.49)$$

onde U_{isol} é o coeficiente global de transferência de calor através do isolamento térmico do circuito, considerando a convecção com o ar ambiente (valor adotado está no item 6.4.4).

B - Lado Interno dos tubos e tubulações (todo o circuito): $r=1 \rightarrow R$

$i = 1$

se o início da Região é em um nó do Tipo 1:

$$\frac{\partial T_{p,r,1}}{\partial t} = \frac{Q_r}{V_{r,1}} [T_{p_{ra,ii(ra)}} - T_{p,r,1}] - \frac{[Wp_{r,1} - Ap_{r,1} q_{p''_{r,1}}]}{\rho_{r,1} V_{r,1} c_{p,r,1}} \quad (6.50)$$

onde Q_r é a vazão correspondente à posição da região (Q_R , Q_A , ou Q_D)

se o início da Região é em um nó do Tipo 2:

$$\frac{\partial T_{p,r,1}}{\partial t} = \frac{1}{V_{r,1}} \{ Q_{ra1} [T_{p_{ra1,ii(ra1)}} - T_{p,r,1}] + Q_{ra2} [T_{p_{ra2,ii(ra2)}} - T_{p,r,1}] \} - \frac{[Wp_{r,1} - Ap_{r,1} q_{p''_{r,1}}]}{\rho_{r,1} V_{r,1} c_{p,r,1}} \quad (6.51)$$

onde Q_{ra1} é a vazão correspondente a uma das regiões anteriores à região r e Q_{ra2} é a vazão da outra região, conforme definições de *nó tipo 2* da Figura 6.4.

$i = 2 \rightarrow ii(r)$

$$\frac{\partial T_{p,r,i}}{\partial t} = \frac{Q_r}{V_{r,i}} [T_{p_{r,i-1}} - T_{p,r,i}] - \frac{[Wp_{r,i} - Ap_{r,i} q_{p''_{r,i}}]}{\rho_{r,i} V_{r,i} c_{p,r,i}} \quad (6.52)$$

C - Integração das Equações de Energia

as equações (6.35), (6.37), (6.40), (6.41), (6.44), (6.46), (6.49), (6.50), (6.51) e (6.52) são integradas pelo método de Euler Simples:

$$T_x^{t+\Delta t} = T_x^t + \Delta t \frac{\partial T_x^t}{\partial t} \quad (6.53)$$

Equações de Conservação de Massa e Quantidade de Movimento

Na solução das equações de massa e quantidade de movimento as propriedades da água foram consideradas nas condições médias de temperatura de cada região e não nas condições de cada volume de controle utilizado nas equações de energia. Como cada região é dividida em volumes de controle iguais, as médias de temperatura podem ser obtidas por meio da média aritmética das temperaturas de cada volume de controle:

$$\bar{T}_r = \frac{1}{ii(r)} \sum_i T_{r,i} \quad (6.54)$$

As propriedades físicas da água são avaliadas nessas temperaturas médias por meio de funções de aproximação preparadas especificamente para as condições previstas de operação da bancada ($T \leq 100 \text{ }^\circ\text{C}$). Então são avaliadas as velocidades de escoamento, o número de Reynolds (Re) e o fator de atrito médio de cada região.

A “massa específica” da água, ρ , e a viscosidade, μ , foram aproximadas por funções hiperbólicas para se obter a velocidade de escoamento e o número de Reynolds.

$$\bar{\rho}_r = 998.2 - \frac{0.30362776 (\bar{T}_r - 20)}{1.0 - 0.00490551 (\bar{T}_r - 20)} \quad (6.55)$$

$$\bar{\mu}_r = 2.8 \times 10^{-4} - \frac{3.116659 \times 10^{-6} (\bar{T}_r - 100)}{1.0 + 8.153195 \times 10^{-3} (\bar{T}_r - 100)} \quad (6.56)$$

$$v_r = \frac{Q_r}{A_{ccr}} \quad (6.57)$$

$$\overline{\Re e}_r = \frac{\overline{\rho}_r \overline{v}_r D_{Hr}}{\overline{\mu}_r} \quad (6.58)$$

Os fatores de atrito foram obtidos de uma maneira extremamente simplificada: por meio da correlação de Blasius, para $\Re e > 100$; e, considerados constantes e igual ao limite de $f = 0,1$ para $\Re e \leq 100$. Não se achou necessário escolher várias correlações, em diferentes regimes de escoamento, pois os fatores de atrito seriam multiplicados por um fator de correção, F_C , obtido experimentalmente na bancada de circulação natural.

$$f = \frac{0.316}{(\Re e_r)^{0.25}} \quad (6.59)$$

$$f_C = F_C \times f \quad (6.60)$$

Como no exemplo desenvolvido nesta tese não foi considerado escoamento na linha de desvio da bancada (válvula fechada), somente é resolvida a equação (6.20), com $Q_D = 0$ e $Q_A = Q_R$ (fluido incompressível):

$$\dot{Q}_R = \frac{[\rho z_i + \rho z_s] - [fL_i + fL_s] Q_R^2}{(\rho V_s) + (\rho V_i)} \quad (6.61)$$

Desse modo fica completo o modelo de simulação dos processos termo-hidráulicos da BCN, faltando apenas extrair as informações necessárias sobre os coeficientes de transferência de calor e sobre o fator de correção do atrito, F_C , conforme será detalhado no item 6.4.4.

6.4.3 Implementação dos modelos da rede neural

As equações do modelo da rede neural artificial foram exatamente as mesmas utilizadas no modelo do manipulador do Capítulo 5, acrescentadas apenas as duas unidades adicionais para processamento dos sinais sensórios da *temperatura da água de resfriamento* e da *abertura da válvula de água de resfriamento* como representado na Figura 6.8. O sinal dessas duas unidades é utilizado para correção do sinal de controle principal conforme a equação (6.32).

6.4.4 Dados para simulação

A) Geometria e demais dados da Bancada

Como já mencionado anteriormente, para as simulações desta tese a BCN foi dividida em quatorze (14) regiões. Cada uma dessas regiões foi dividida ainda nos volumes de controle indicados na Tabela 6.1, que também contém as informações de tipos de interface, etc. Os dados referentes às singularidades e comprimentos de tubo (*trecho reto*) utilizados para estimativas de perda de carga estão na Tabela 6.2. A Tabela 6.3 contém as coordenadas de início e fim de cada região (como exemplifica a Figura 6.11), utilizados apenas pelas subrotinas de apresentação gráfica do programa do Apêndice 2, e contém ainda os dados de áreas, volumes de água e capacidade térmica das partes metálicas.







Figura 6.11 - Exemplo de coordenadas.

Tabela 6.1 - Definições de nós e interfaces.

Região	Número de Volumes	Tipo de nó de entrada (Figura 6.4)	Tipo de interfaces (Figura 6.9)	1ª Região Anterior	2ª Região Anterior	Posição
1	5	1	2	14	-	1
2	5	1	1	1	-	1
3	5	1	7	2	-	1
4	5	1	2	3	-	1
5	5	1	1	4	-	1
6	5	1	9	5	-	0
7	5	1	8	5	-	2
8	5	1	9	7	-	2
9	2	1	4	8	-	2
10	5	1	11	9	-	2
11	2	1	11	10	-	2
12	3	1	11	11	-	2
13	5	2	11	12	6	1
14	2	1	10	13	-	1

Tabela 6.2 - Dados para Perda de Carga.
(incluindo o número de singularidades por tipo e por região)

Região	Diam. Hidrául. (m)	União (20) ^(*)	"Tê"  (20) ^(*)	"Tê"  (60) ^(*)	Curva (30) ^(*)	Válv. Esfera (30) ^(*)	 (50) ^(*)	Trecho Reto (m)	Leq. Total (m)
1	0.0381	-	8	1	-	-	1	0.5	283.1
2	0.007945	-	-	-	-	-	2	0.635	179.9
3	0.0381	-	8	-	-	-	1	0.5	223.1
4	0.0208	3	1	-	1	1 ^(**)	-	2.995	284.0
5	0.0208	2	-	-	-	1	-	2.426	186.6
6	0.0208	4	1	2	2	2	-	4.17	540.5
7	0.0208	3	2	-	1	1	-	2.306	270.9
8	0.0208	-	-	-	1	-	-	4.17	230.5
9	0.0208	1	-	-	1	-	1	0.078	103.8
10	0.0144	-	-	-	-	-	-	1.7	118.1
11	0.0144	-	-	-	-	-	1	0.128	58.9
12	0.0208	1	1	-	-	-	-	0.378	58.2
13	0.0208	-	1	1	-	-	-	3.083	228.2
14	0.0208	1	1	-	-	-	-	0.175	48.4

(*) L/D - Comprimento equivalente de perda de pressão, com base no diâmetro da tubulação

(**) Medidor de vazão

Tabela 6.3 - Dados gerais de posição, áreas e volumes.

Região	Coordenadas das Regiões ^(*) (m)				Área Esc. (m ²)	Vol. (m ³)	$\frac{V}{\rho_M A_M C_M}$
	x(1)	y(1)	x(2)	y(2)			
1	1.175	7.301	1.675	7.301	0.00114	0.00114	0.0006889
2	1.675	7.301	1.675	6.644	0.0008924	0.000527	0.0007267
3	1.675	6.644	2.175	6.644	0.00114	0.00114	0.0006889
4	2.175	6.644	5.170	6.644	0.0003398	0.001018	0.0070302
5	5.170	6.644	5.170	4.218	0.0003398	0.000824	0.0070302
6	5.170	4.218	1.000	4.218	0.0003398	0.001417	0.0070302
7	5.170	4.218	5.170	1.934	0.0003398	0.000818	0.0070302
8	5.170	1.934	1.000	1.934	0.0003398	0.001417	0.0070302
9	1.000	1.934	1.000	2.012	0.0003398	0.000027	0.0070302
10	1.000	2.012	1.000	3.712	0.00188	0.00374	0.0002829
11	1.000	3.712	1.000	3.840	0.00188	0.00033	0.004763
12	1.000	3.840	1.000	4.218	0.0003398	0.000176	0.0070302
13	1.000	4.218	1.000	7.301	0.0003398	0.001048	0.0070302
14	1.000	7.301	1.175	7.301	0.0003398	0.0000595	0.0070302

Outros dados necessários para a simulação são:

- Número da região do aquecedor - 10
- Superfície das resistências do aquecedor - 0.474255 m²
- Dados do secundário do trocador de calor:

	Região 1	Região 2	Região 3
Perímetro aquecido - externo (m)	0.139644	0.538626	0.139644
Área de troca de calor - ext. (m ²)	0.139644	0.342028	0.139644
Área de escoamento - sec. (m ²)	0.2056	0.2500	0.2056
Compr. dos volumes Δs (m)	0.100	0.127	0.100

- Coeficiente de transf. de calor pelo isolamento - 2,0 W/m² °C
- Potência máxima do aquecedor (para SC = 1) - 2250 W
- $\Delta p C_{v_{max}}$ (equações 6.30 e 6.31) - 0.000131

Para verificar a precisão do modelo de simulação da bancada, estimar os coeficientes de transferência de calor no trocador de calor (h_p e h_s das equações 6.28 e 6.29), e obter o fator de correção aplicado sobre os fatores de atrito (F_C , equação 6.60), foi neces-

^(*) Dados utilizados pela parte de apresentação gráfica do programa.

sária a realização de um experimento na BCN. Esses valores foram obtidos de um transiente provocado por um degrau inicial de potência de zero a 2230 W, mantida essa potência por um período de 6:00 h. Nesta parte do trabalho somente serão analisadas as primeiras 4:27 h, quando a vazão de água de resfriamento foi mantida constante em 60 l/h, a temperatura da água de resfriamento permaneceu inalterada em 18,3 °C e a temperatura ambiente também não variou, ficando em torno de 18,0 °C. A Figura 6.12 mostra as medidas de vazão no primário e de potência no aquecedor, além de resultados de cálculos, por meio de balanço térmico ($Q = \dot{m} c_p \Delta T$), da potência no lado primário e no lado secundário do trocador de calor. Observa-se que devido a enorme capacidade térmica do trocador de calor, decorrente da grande massa de água (202 litros), o calor extraído na água de resfriamento ainda não atingiu regime permanente. Observa-se também que esse calor não irá convergir para a potência do aquecedor ou do lado primário pois ocorrem muitas perdas de calor no secundário do trocador de calor, tanto pelas paredes como por evaporação de água pois há uma grande superfície livre. Essas observações mostram ser conveniente incluir todas as perdas como parte do coeficiente global de transferência de calor, mesmo que se produzam resultados falsos na temperatura de saída da água de resfriamento. Isso permite uma simplificação na simulação sem produzir erros nas variáveis de maior interesse para o controle.

Com base nessas considerações foram feitos os cálculos de diferença média logarítmica de temperaturas ($\overline{\Delta T}_{LOG}$) e estimativas do produto da área de transferência de calor pelo coeficiente global de transferência de calor (U), conforme o diagrama da Figura 6.13 e as equações (6.62) e (6.63). Os resultados são mostrados na Figura 6.14.




Figura 6.12 - Medidas experimentais e balanço térmico no T.C.

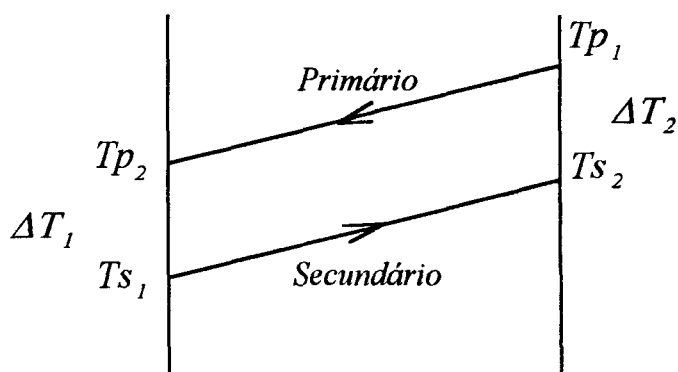


Figura 6.13 - Diagrama de temperaturas no T.C.

$$\overline{\Delta T}_{LOG} = \frac{\Delta T_1 - \Delta T_2}{\text{LOG}_N(\Delta T_1 / \Delta T_2)} \quad (6.62)$$

$$\overline{U A} = \frac{Q}{\overline{\Delta T}_{LOG}} \quad (6.63)$$




Figura 6.14 - Cálculos de $\overline{\Delta T}_{LOG}$ e estimativa do produto \overline{UA} no T.C.

Apesar de se observar, exclusivamente na fase inicial do transiente, variações do coeficiente global de transferência de calor com a vazão e com a temperatura da água do primário, verificou-se que essas variações não chegaram a 15%. Isso é justificável pois o coeficiente de transferência de calor no lado secundário do trocador de calor deve dominar, e sua variação esperada não é grande. Considerando isso, e como a finalidade do experimento foi a obtenção de estimativas que apenas não levassem as simulações a resultados sem significado físico, considerou-se adequada a utilização de um único valor para cada coeficiente de transferência de calor, obtidos de modo a reproduzir o valor da média temporal de UA , que foi igual a aproximadamente 133 W/°C, conforme Figura 6.14. Isso foi feito realizando testes de alguns valores para os coeficientes locais de transferência de calor, que

foram variados em conjunto com o fator de correção do atrito (F_C). Os coeficientes locais de transferência de calor que aproximaram razoavelmente os resultados experimentais são mostrados na Tabela 6.4. Cada um deles foi considerado constante ao longo de cada uma das três regiões do T.C.

Tabela 6.4 - Coeficientes de transferência de calor assumidos por região do T.C.

Região	hp (W/m ² °C)	hs (W/m ² °C)
1	500.	500.
2	645.	645.
3	500.	500

As simulações realizadas, com esses coeficientes de transferência de calor, indicaram que os fatores de atrito devem ser 2,2 vezes maiores que os estimados com os dados das tabelas de comprimento equivalente, associadas ao atrito distribuído de Blasius, ou seja, $F_C = 2,2$. Com isso, finalmente foi possível reproduzir com boa precisão o experimento realizado, como mostra a Figura 6.15.

B) Dados da rede neural

Os dados utilizados na simulação da rede neural da Figura 6.8 estão na Tabela 6.5. Foram utilizados os mesmos valores do modelo do manipulador robótico do Capítulo 5, à exceção do número de terminais e dos valores das constantes λ e a_s . A constante de decaimento da força de ligação das sinapses plásticas, λ , foi reduzida em cem vezes (de 10 para 0.1) em função da lentidão dos processos envolvidos na circulação natural (essa redução foi determinada após a realização de alguns testes). A constante a_s das sinapses facilitadoras somente foi alterada devido à mudança do intervalo entre limiares, sua relação com a constante a das sinapses plásticas continuou a mesma: $\frac{a_s}{a} = \frac{144}{28.8} = \frac{100}{20} = 5$. Observa-se ain-

da que, pela necessidade de ativação e desativação do processo de plasticidade (conforme será explicado no item referente ao treinamento), T_C assumiu dois valores: 0 ou 1.

Tabela 6.5 - Dados da rede neural.

Parâmetro	Valor
“Tamanho” das unidades - T_N	2.1
Constante de ganho das unidades - α	0.5
Constante das sinapses plásticas da unidade motora - α	20.0
Número de terminais dos axônios sensórios c/ as unidades motoras - kk	13
Número de terminais dos axônios dos “desejos” c/ as unidades motoras - jj	13
Intervalo entre limiar de terminais consecutivos - $\Delta x = x_{j+1}^0 - x_j^0 = x_{k+1}^0 - x_k^0$	0.2
Força de ligação das sinapses de erro - $T\varepsilon$	2.5
Força de ligação das sinapses de taxas - Tr	0.09
Força de ligação das sinapses facilitadoras - Tc	0 / 0.1
Constante de decaimento das sinapses plásticas - λ	0.1
Constante das sinapses facilitadoras - α_s	100.0




Figura 6.15 - Comparação da evolução das temperaturas e vazão calculadas com as medidas no teste de validação.

6.5 Resultados

6.5.1 Treinamento da Rede

O treinamento dessa nova rede também foi desenvolvido durante a execução de comandos de ação. Foram montadas tabelas contendo os “desejos” comandados ao controlador, que constituem o universo de treinamento, e ainda, as perturbações. Diferente do realizado no exemplo do manipulador bi-articulado, foram montadas três tabelas de treinamento, cada uma específica para uma dada variável: *a temperatura desejada*, *a perturbação na vazão de resfriamento* e *a perturbação na temperatura da água de resfriamento*. O treinamento foi desenvolvido em três etapas distintas, de acordo com essas três tabelas de treinamento (Tabelas 6.6 a 6.8). Os efeitos não foram sobrepostos, enquanto se realizava o treinamento sobre uma das variáveis em mudança, a plastificação das sinapses dos neurônios de saída correspondentes às outras unidades ficava “congelada”, ou seja, a força de ligação das sinapses facilitadoras com essas unidades, T_c , assumia o valor zero.

Cada etapa do treinamento foi realizada em sessões, observando-se a evolução gradual do aprendizado. A 1ª etapa consistiu da repetição, por 3 vezes, das 7 condições especificadas na Tabela 6.6, totalizando $3 \times 7 \times 14400 = 302400$ segundos de tempo de processo simulado. A 2ª etapa consistiu da repetição por 2 vezes das 9 condições da Tabela 6.7, totalizando mais $2 \times 9 \times 12800 = 230400$ segundos. Na 3ª e última etapa foi realizada uma primeira sessão com o tempo de 10800 segundos para a primeira condição e 3600 segundos para cada uma das demais, e uma segunda sessão considerando 7200 segundos para a primeira condição e novamente 3600 segundos para as demais, totalizando $1 \times 10800 + 1 \times 7200 + 2 \times 9 \times 3600 = 82800$ segundos. Portanto todo o treinamento representou um total de 615600 segundos de processo simulado, ou seja, 171 horas.

Tabela 6.6 - Dados de variação na Temperatura desejada.

Condição	Duração (s)	T _{amb} (°C)	Temp. Resfr.	A (válvula)	Temp. Desejada
1	14400.	25.0	20.0	0.25	30.00
2	14400.	25.0	20.0	0.25	35.00
3	14400.	25.0	20.0	0.25	40.00
4	14400.	25.0	20.0	0.25	45.00
5	14400.	25.0	20.0	0.25	50.00
6	14400.	25.0	20.0	0.25	55.00
7	14400.	25.0	20.0	0.25	25.00

Tabela 6.7 - Dados de variação na Temperatura da água de resfriamento.

Condição	Duração (s)	T _{amb} (°C)	Temp. Resfr.	A (válvula)	Temp. Desejada
1	12800.	25.0	14.0	0.25	50.00
2	12800.	25.0	16.0	0.25	50.00
3	12800.	25.0	18.0	0.25	50.00
4	12800.	25.0	20.0	0.25	50.00
5	12800.	25.0	22.0	0.25	50.00
6	12800.	25.0	24.0	0.25	50.00
7	12800.	25.0	26.0	0.25	50.00
8	12800.	25.0	28.0	0.25	50.00
9	12800.	25.0	30.0	0.25	50.00

Tabela 6.8 - Dados de variação na abertura da válvula da água de resfriamento.

Condição	Duração (s)	T _{amb} (°C)	Temp. Resfr.	A (válvula)	Temp. Desejada
1	1x10800. 1x7200.	25.0	20.0	0.05	50.00
2	2x3600.	25.0	20.0	0.10	50.00
3	2x3600.	25.0	20.0	0.15	50.00
4	2x3600.	25.0	20.0	0.20	50.00
5	2x3600.	25.0	20.0	0.25	50.00
6	2x3600.	25.0	20.0	0.30	50.00
7	2x3600.	25.0	20.0	0.35	50.00
8	2x3600.	25.0	20.0	0.40	50.00
9	2x3600.	25.0	20.0	0.45	50.00
10	2x3600.	25.0	20.0	0.50	50.00

Após cumpridas essas três etapas de treinamento, o sistema, constituído pelo controlador neural acoplado ao processo da BCN, foi capaz de atender, de uma maneira considerada adequada, todos os comandos de temperatura desejada, efetuados sob diversas condições de perturbação de abertura da válvula e de variação na temperatura da água de resfriamento. As forças de ligação dos terminais sinápticos plásticos (definidas pelos T_j e T_k 's da primeira unidade motora e pelos T_j 's das unidades de ajuste de perturbações) cresceram, nas respectivas etapas do treinamento, do valor inicial *zero* para os valores ilustrados nas Figuras 6.16 a 6.18. A Tabela 6.9 mostra o conjunto dos resultados finais, ou seja, após as três etapas, indicando ainda quais são os valores de cada uma das variáveis correspondentes a cada limiar, na forma das variáveis T_L , T_{SL} e Av_L . O treinamento sobre o tempo simulado de 171 horas foi realizado consumindo apenas 1:48h de CPU (somatória dos tempos de todas as etapas) em um microcomputador PENTIUM de 166 MHz.




Figura 6.16 - Forças de ligação sináptica após 1ª Etapa.




Figura 6.17 - Forças de ligação sináptica após 2ª Etapa.




Figura 6.18 - Forças de ligação sináptica após 3ª Etapa.

Tabela 6.9 - Forças de Ligação Sináptica após treinamento.

Unidade Motora Nº 1 (principal)			Unidade Motora Nº 2 (de T_{sec})			Unidade Motora Nº 3 (de A_{valv})		
Limiar		$T_j = T_k$	Limiar		T_l	Limiar		T_m
x_0	T^*		x_0	T^*		x_0	Av^*	
-1.2	20.	-0.00116928	-1.2	8.	0.00325479	-1.2	-	-0.00936843
-1.0	25.	-0.01734568	-1.0	10.	0.00772838	-1.0	0.0	-0.02993143
-0.8	30.	0.01765643	-0.8	12.	0.02724423	-0.8	0.05	-0.14430515
-0.6	35.	0.01809756	-0.6	14.	0.13692694	-0.6	0.10	-0.06387486
-0.4	40.	0.03515421	-0.4	16.	0.07133455	-0.4	0.15	-0.03213661
-0.2	45.	0.07098319	-0.2	18.	0.03562834	-0.2	0.20	-0.01834903
0.0	50.	0.16443447	0.0	20.	0.00658684	0.0	0.25	-0.01436435
0.2	55.	0.32179213	0.2	22.	-0.02578953	0.2	0.30	-0.01271007
0.4	60.	0.06681620	0.4	24.	-0.06454596	0.4	0.35	-0.01153588
0.6	65.	0.02090895	0.6	26.	-0.11489901	0.6	0.40	-0.01071234
0.8	70.	0.01001677	0.8	28.	-0.18304337	0.8	0.45	-0.01018060
1.0	75.	0.00586774	1.0	30.	-0.24736433	1.0	0.50	-0.00923484
1.2	80.	0.00385504	1.2	32.	-0.05280998	1.2	0.55	-0.00260057

6.5.2 - Testes de Desempenho

Apesar do pouco treinamento realizado, com as forças de ligação sináptica mostradas na Tabela 6.9, já foi iniciada a fase de testes para avaliar o desempenho da rede de controle. Essa avaliação focalizou principalmente a capacidade de generalização, ou seja, a execução de comandos não presentes nas tabelas de treinamento. Do mesmo modo que o realizado com o manipulador apresentado no Capítulo 5, na fase de testes foram bloqueados os mecanismos de plasticidade anulando-se a força de ligação de todas as sinapses facilitadoras, $T_c = 0$. A partir daí foram executados testes sobre todo o domínio possível, limitado é claro pelas condições impostas pelo processo em si. Por exemplo, fisicamente não é possível que, com a água de resfriamento a $20\text{ }^{\circ}\text{C}$ e a abertura da válvula da água de resfriamento em $A = 0,50$, a maior temperatura no circuito ultrapasse $\approx 56\text{ }^{\circ}\text{C}$, ou que, com a água

de resfriamento a $10\text{ }^{\circ}\text{C}$ e a abertura da válvula da água de resfriamento em $A = 0,25$, a maior temperatura no circuito ultrapasse $\approx 48\text{ }^{\circ}\text{C}$.

Para apresentação de um resultado típico foi escolhida a simulação de diversos transitórios dentro de uma única operação, iniciada sob condições normais com $T_{amb} = 25\text{ }^{\circ}\text{C}$ e $T_{sec} = 20\text{ }^{\circ}\text{C}$. O teste se inicia com a solicitação de atingir as condições médias consideradas no treinamento, ou seja, uma temperatura de $50\text{ }^{\circ}\text{C}$ na saída do aquecedor, com a vazão de água de resfriamento determinada pela abertura da válvula de regulação em 25%. O teste prossegue com as condições mostradas na Tabela 6.10.

Tabela 6.10 - Dados para apresentação dos testes de desempenho.

Condição	Duração (s)	T_{amb} ($^{\circ}\text{C}$)	Temp. Resfr.	A (válvula)	Temp. Desejada
1	16000.	25.0	20.0	0.25	50.00
2	7200.	25.0	23.0	0.25	50.00
3	7200.	25.0	25.0	0.25	50.00
4	7200.	25.0	25.0	0.25	55.00
5	7200.	25.0	25.0	0.12	55.00
6	7200.	25.0	25.0	0.08	55.00
7	7200.	25.0	25.0	0.08	60.00
8	7200.	25.0	25.0	0.08	33.00
9	7200.	25.0	15.0	0.08	33.00
10	7200.	25.0	15.0	0.08	53.00
11	7200.	25.0	15.0	0.08	42.00
12	7200.	25.0	17.0	0.33	37.00

A escolha da duração das condições da Tabela 6.10 se deu em função das características do processo de circulação natural, que em um sistema como o da BCN é muito lento, fazendo com que uma perturbação produza resultados somente após um enorme intervalo de tempo. Sabendo-se disso e, uma vez que um experimento sob condições tão

controladas como as da Tabela 6.10 seria praticamente inviável, não se considerou necessário nem razoável produzir testes de desempenho nos quais houvesse tempo para as perturbações produzirem estabilidade de regime. Considerou-se porém, que deveria haver um período razoável apenas para observar a evolução e tendências do sistema controlado. Para determinar esse tempo de estabilização “parcial” do sistema foram analisadas informações do teste apresentado parcialmente no item 6.4.4, onde foram mostrados os primeiros 16000 segundos de teste. Uma informação resultante daquele teste é mostrada agora na Figura 6.19, onde se observa a evolução da temperatura na saída do aquecedor (TC-22), da temperatura da água de resfriamento na saída do trocador de calor (TC-18), e da potência no aquecedor. O que se vê, é que de fato, o regime permanente tenderia a ser atingido após um intervalo de aproximadamente 22000 segundos, porém as temperaturas no primário atingem quase 100% dos valores de regime bem antes, logo após os primeiros 16000 segundos. Tendo em vista essa constatação foi decidido (como se depreende da Tabela 6.10) deixar um período de tempo suficiente apenas para a estabilização parcial das temperaturas do primário em condições quase de regime permanente somente para a primeira condição do teste. Para as condições seguintes considerou-se um período aproximado de 1/3 do período estimado para a estabilização, ou seja, 7200 segundos.

A simulação do teste completo da Tabela 6.10, representando 95200 segundos de tempo real de processo, consumiu apenas 16 minutos e 35 segundos (≈ 1000 s) de CPU em um computador com processador PENTIUM de 166 MHz com Windows 98 como sistema operacional.

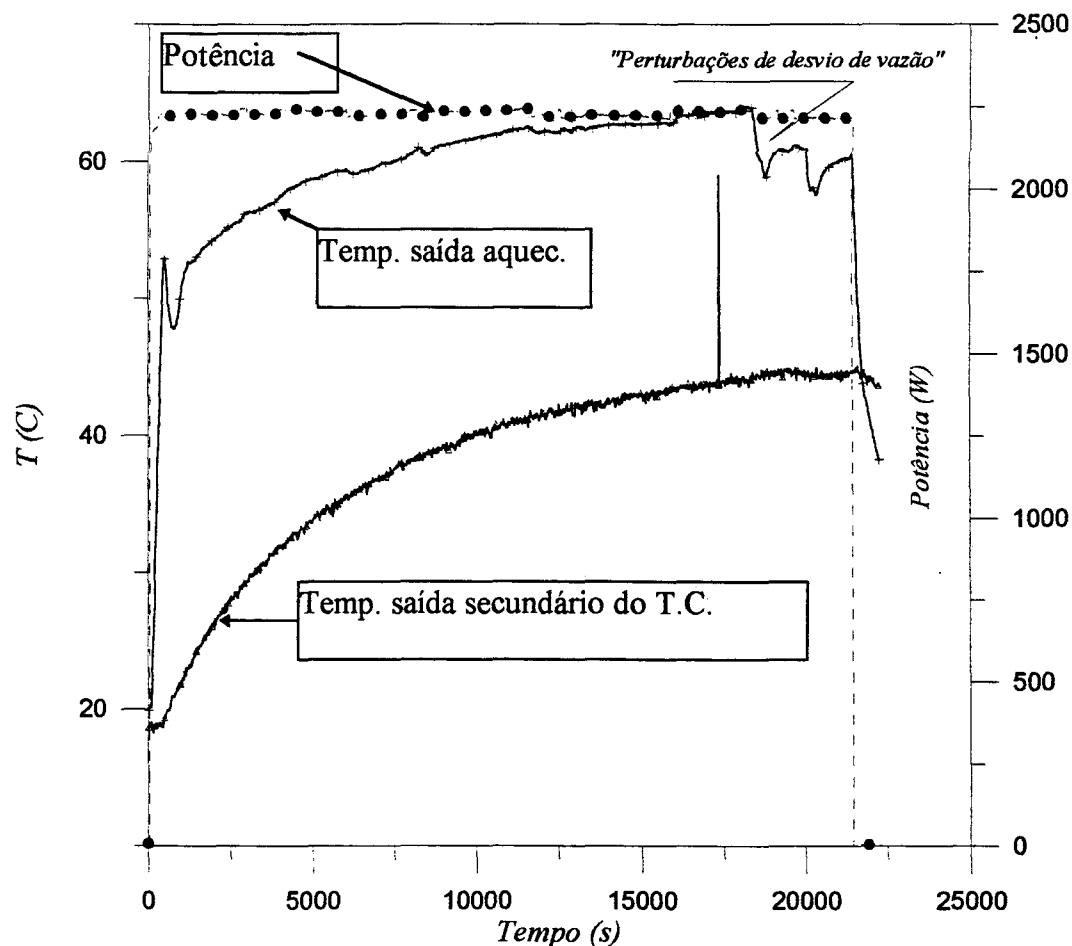


Figura 6.19 - Evolução das temperaturas no primário e secundário do T.C.

Na Figura 6.20 é mostrado o que representaram as perturbações da Tabela 6.10 em relação às condições de treinamento e ao seu efeito na relação entre *desejo e observação*.

A Figura 6.20 foi construída calculando-se a relação entre as perturbações e observações e as condições originais do treinamento, ou seja: *Temperatura de água de resfriamento / 20; Abertura da válvula / 0,25; Temperatura desejada / 50*. Alguns valores utilizados estavam fora da faixa de treinamento, outros entre dois valores existentes no treinamento, porém não coincidentes com esses. As perturbações relativas representaram relações

entre 32% e 125% das condições médias do treinamento (condições do limiar zero). A Figura 6.21 mostra os valores absolutos dessas perturbações.




Figura 6.20 - Perturbações relativas.

O erro na temperatura desejada, definido pela diferença entre a temperatura observada e a temperatura desejada, ($T - T_{des}$), é apresentado na Figura 6.22, onde se constata que, somente em três condições, ficou fora de uma faixa de $\pm 0,5$ °C, sendo: uma por falta de tempo para acomodação da perturbação; outra somente justificada por se combinarem as duas maiores perturbações: *Temperatura de resfriamento de 15 °C*, e *Abertura da válvula de 0,08*; e a terceira onde se combinou a perturbação de *Abertura da válvula 0,08*

com a demanda de uma temperatura desejada 5 °C acima da maior temperatura considerada no treinamento, ou seja $T_{des}=60$ °C.

Mesmo com essas observações pode ser considerado que o sistema de controle foi muito bem sucedido na característica de capacidade de generalização.




Figura 6.21 - Perturbações absolutas e resultados observados.




Figura 6.22 - Evolução do erro de temperatura.

O objetivo principal do trabalho, que foi o desenvolvimento de um conceito inovador no campo de redes neurais artificiais para controle de sistemas dinâmicos com aplicação na tecnologia de reatores, foi plenamente atingido, como mostraram os resultados das redes desenvolvidas para o controle de um manipulador bi-articulado e para o controle de temperatura da bancada de circulação natural.

Os novos conceitos introduzidos com essa arquitetura foram baseados no projeto de redes dedicadas à tarefa, na utilização de múltiplos contatos sinápticos com uma nova função de transferência, e no uso de processos de modificação de forças de ligação sinápticas similares aos de organismos biológicos. Esses conceitos implementam aspectos evolucionários de sistemas biológicos, tanto na arquitetura, quanto nos processos de transmissão de sinais, memória e aprendizado, propiciando uma capacidade de generalização não obtida por meio de outras redes neurais artificiais.

O desempenho obtido, principalmente no problema do manipulador que caracteriza um sistema de dinâmica mais complexa, mostrou que a utilização de redes especializadas por tarefa produz resultados muito melhores que os resultados obtidos com a utilização de redes genéricas, como a rede tipo “feedforward” (F-F) treinada pelo Método de Retro-propagação. A comparação dos resultados, apresentada no Capítulo 5, mostrou que para o novo modelo de rede neural proposto não se obteve erros de posicionamento maiores que 5 mm, enquanto que para a rede tipo F-F com treinamento por retro-propagação os

erros atingiram quase 300 mm, mesmo após a complementação do treinamento especificamente sobre os pontos do teste.

Foi demonstrado que a similaridade dos novos conceitos com sistemas biológicos, principalmente nas características das conexões sinápticas, incrementa a capacidade de integração de cada unidade e, apesar de uma maior complexidade aparente, oferece um ganho real de desempenho pela grande redução de unidades (neurônios). A complexidade adicional decorrente do conceito de sinapses múltiplas é compensada pela redução no número de unidades com funções hiperbólicas dispendiosas em termos de processamento.

A construção de arquiteturas dedicadas juntamente com o uso de múltiplos contatos sinápticos, aproveitando o conhecimento dos aspectos evolucionários dos sistemas biológicos, tanto na sua arquitetura quanto nos seus processos de transmissão de sinais e de memorização, propicia uma capacidade de generalização não obtida por meio de redes clássicas tipo F-F. Para a nova rede não foi necessário nenhum treinamento adicional para serem atingidos precisamente alvos fora do universo de treinamento. Para a rede tipo F-F foram necessários, no caso do braço robótico, pelo menos 120 repetições de treinamentos dedicados exclusivamente aos novos alvos.

Os conceitos considerados na nova arquitetura de rede, desenvolvidos com base nos circuitos biológicos envolvidos nos mecanismos de habituação, sensitização, condicionamento clássico e prática, permitem a realização de treinamento não-supervisionado, mostrando portanto grande superioridade em relação às redes neurais artificiais ainda utilizadas em controle. O novo conceito utiliza um sistema de alteração de forças de ligação sinápticas embutido nos componentes dos próprios caminhos de sinalização, e não por meio de algum algoritmo externo a esses caminhos como no caso da retro-propagação. Isso per-

mite o treinamento durante a execução de comandos de ação. A tarefa de treinamento da nova rede foi 150 vezes mais rápida do que com o método de retro-propagação associado à rede tipo F-F.

Para a utilização dos novos conceitos em uma aplicação de controle de um sistema termo-hidráulico foi introduzido um novo conceito: *a utilização de sinais de perturbações para alteração de ganhos no controlador*. Esse conceito, mostrado no Capítulo 6, permitiu a partir da variação da potência do aquecedor da bancada de circulação natural o controle da temperatura de modo a compensar grandes perturbações. Nessas condições, os erros de temperatura observados ficaram em média dentro de uma faixa de $\pm 0,5$ °C, somente saindo dessa faixa em duas condições. Mesmo com a influência de outras variáveis, os erros observados nos testes realizados sob condições fora das condições de treinamento permitem concluir que o sistema de controle foi também muito bem sucedido na sua capacidade de generalização.

8 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

A simulação das redes apresentadas por meio dos programas digitais desenvolvidos, mostrou um ótimo desempenho computacional permitindo que se vislumbrem novas oportunidades de desdobramento para os conceitos empregados.

Os novos conceitos foram aplicados no controle de um manipulador bi-articulado no plano e no controle da temperatura da água de uma bancada experimental operando em circulação natural. Os modelos utilizados nessas aplicações podem ser considerados simples, principalmente porque não foram feitas transformações de sistemas de coordenada ou qualquer outro tipo de abstração. Por exemplo, para o controle do manipulador foram sempre fornecidas as entradas na forma de *ângulos desejados* e *ângulos observados*. Esses dados poderiam ser fornecidas de outras maneiras, como por exemplo na forma de pares de coordenadas (x, y) , ou em forma de informações visuais de posição. Para isso, a mesma rede poderia ser utilizada desde que houvesse uma outra rede, colocada em um nível hierárquico superior, e que fosse previamente treinada para promover a conversão dos dados. Do mesmo modo, todos os problemas tratados no manipulador foram problemas de *posicionamento*, enquanto que poderiam ser tratados problemas mais complexos de *trajetória*. Também para esse tipo de abstração deve-se ter novos níveis hierárquicos, que por exemplo, produzissem a contínua mudança das condições desejadas.

Se a rede básica de controle, semelhante a um circuito neuronal de reflexo confinado na medula de um ser humano, puder receber as informações de mudanças desejadas, nos instantes adequados, poderá controlar o manipulador para seguir uma trajetória

qualquer. Para ilustrar essa idéia, apresenta-se na Figura 8.1, o resultado obtido com a mesma rede do Capítulo 5, quando alimentada por 105 mudanças de comando de posição realizadas em um período de 20 segundos, para que seguisse uma trajetória linear entre as posições de -90° e 0° . Para a estabilização no ponto final foi deixado um tempo adicional de 6.4 segundos. A duração de cada um dos comandos de posicionamento utilizados foi obtida por tentativa e erro, pois ainda não foi possível investir no desenvolvimento de novos programas de simulação, o que poderá ser um trabalho futuro.

Pode ser observado na Figura 8.1 que, apesar desta rede não ter sido desenvolvida para esse propósito, existe a capacidade para conduzir a extremidade do manipulador segundo uma dada trajetória.




Figura 8.1 - Deslocamento do manipulador para atender trajetória retilínea.

Com relação ao processo de treinamento, é importante lembrar que foram feitas comparações com uma rede treinada pelo algoritmo de retro-propagação, sendo interessante desenvolver outros trabalhos procurando sua comparação com redes competitivas, treinadas por meio de algoritmos não-supervisionados, como por exemplo o método de Kohonen.

Finalmente é interessante observar que, a utilização do conceito de alteração de ganho em função de perturbações produz o efeito de uma *multiplicação*, ou seja, esse conceito pode ser utilizado no controle do manipulador produzindo um sistema robusto a mudanças de massa, uma vez que a compensação do efeito de uma massa transportada na extremidade do manipulador requer o aumento do ganho dos sinais de controle na produção dos torques e, essa mudança é proporcional à massa.

APÊNDICE 1

PROGRAMA DE SIMULAÇÃO DO MANIPULADOR BI-ARTICULADO

O programa *NEUROSGD.F90* foi desenvolvido considerando as seguintes interfaces de entrada de dados: a) um arquivo contendo os dados físicos do manipulador, *bracos.dat*; b) um arquivo contendo os dados especificados para a rede neural de controle, *neurosg.dat*; c) um arquivo contendo uma tabela de alvos (pares θ_{1D} e θ_{2D}) para definir um universo de treinamento, *treino.dat*; d) um arquivo gerado automaticamente pelo programa após o início de um treinamento contendo, além dos dados especificados para a rede neural de controle, os dados gerados pela seção de treinamento, *neurosg2.dat*; e) uma caixa de diálogo que é utilizada para a entrada das informações referentes a opções de início, intervalos de atualização gráfica da tela principal, e condições de contorno para a simulação, conforme mostrado na Figura A1.1; e, f) a janela principal de execução do programa, exibida na Figura A1.2, que além de permitir o acompanhamento da evolução do treinamento, é utilizada para a entrada dos ângulos desejados, no caso de opção de resposta a comandos, da duração da ação, e se vai haver continuação ou se encerra a simulação ao término do tempo especificado.

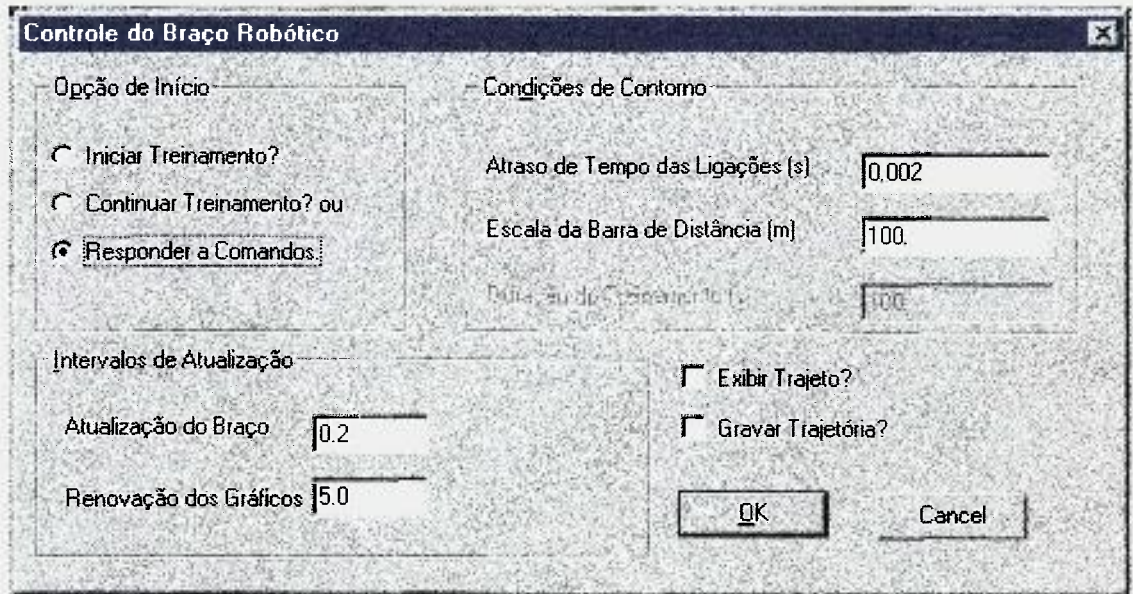



Figura A1.1 - Caixa de Diálogo do Programa do Manipulador.

Painel de Controle

Teclle (ESC) para
Finalizar



L (seg)

26.4
100
90
80
70
60
50
40
30
20
10
0

Distancia
2.8mm

Teta 1

D .0
R -.1

Teta 2

D .0
R .4

"Tamanho" - J = 1

"Tamanho" - J = 2




Figura A1.2 - Tela Principal do Programa do Manipulador.

APENDICE 2

PROGRAMA DE SIMULAÇÃO DA BANCADA DE CIRCULAÇÃO NATURAL

No desenvolvimento do programa de simulação decidiu-se pela elaboração de um programa computacional genérico, ou seja, *que pudesse ser utilizado posteriormente para modelar outros sistemas*. Para esse programa, *BANCADA.F90*, foi desenvolvido um método de representação gráfica das saídas com a visualização das temperaturas em escala de cores (Figura A2.1). Para que esse recurso pudesse ser implementado, foi preciso estabelecer que *tipos* de interface entre regiões seriam necessários em função da geometria e das direções de escoamento. Verificou-se que para o modelo unidimensional proposto seria necessário modelar doze (12) tipos de interfaces mostrados na Figura A2.2. Foi dentro dessa convenção que a bancada de circulação natural foi dividida nas 14 regiões mostradas no Capítulo 6.

O programa *BANCADA.F90* foi desenvolvido considerando as seguintes interfaces de entrada de dados:

- a) um arquivo contendo os dados físicos da bancada, *BANCADA.GEO*;
- b) um arquivo contendo os dados especificados para a rede neural de controle, *NEUROBAN.DAT*;
- c) um arquivo contendo as tabelas de condições desejadas (temperaturas), perturbações de temperatura e de abertura da válvula de água de resfriamento, para definir o universo de treinamento, *BANCADA.TRE*;

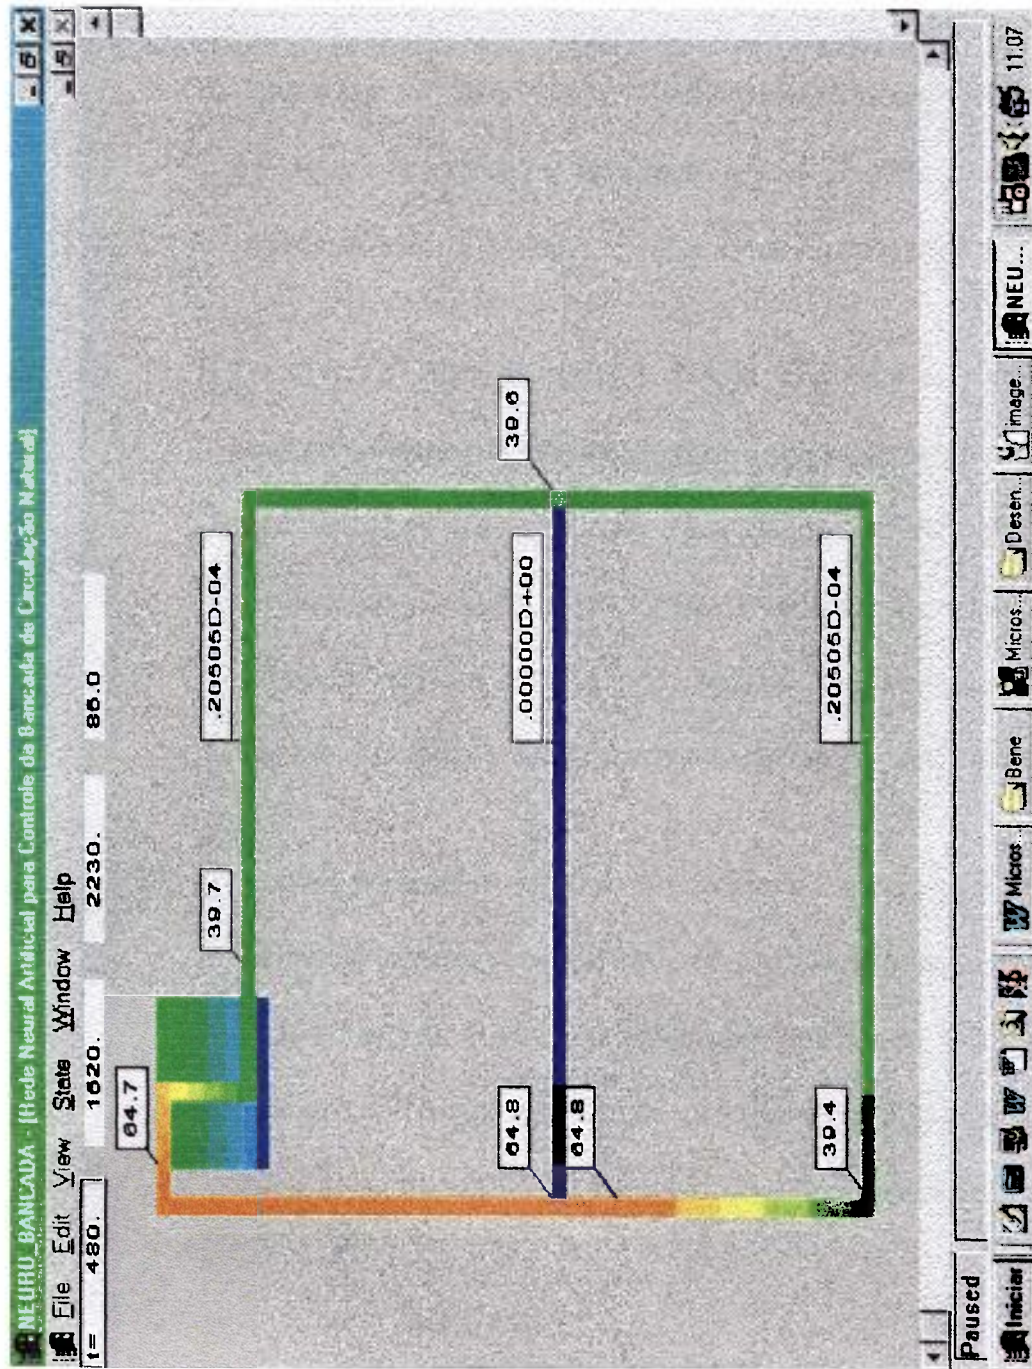


Figura A2.1 - Tela Principal de acompanhamento do processo.

- d) um arquivo gerado automaticamente pelo programa após o início de um treinamento contendo, além dos dados especificados para a rede neural de controle, os dados gerados pela seção de treinamento, *neuban2.dat*;
- e) uma caixa de diálogo para a entrada das informações referentes a opções de início, intervalos de atualização gráfica da tela principal, e tipo de opção de entrada de dados, conforme mostra a Figura A2.3;
- f) uma outra caixa de diálogo para a entrada das condições iniciais especificadas para a simulação, caso a opção de entrada de dados seja por *caixa de diálogo*, nesse caso devem ser fornecidos dados de temperatura ambiente, temperatura da água do secundário, temperatura desejada, abertura da válvula de água de resfriamento (de 0 a 1.0), e duração da etapa de simulação, conforme mostra a Figura A2.4; e,
- g) a janela principal de execução do programa, exibida na Figura A2.1, que permite o acompanhamento da evolução das temperaturas ao longo de toda a bancada. No caso de opção por entrada de dados por caixa de diálogo, ao término da duração de cada etapa é exibida uma pequena caixa de diálogo de opção entre *finalizar?* ou *novos dados?*.




Figura A2.2 - Tipos possíveis de interface entre regiões.

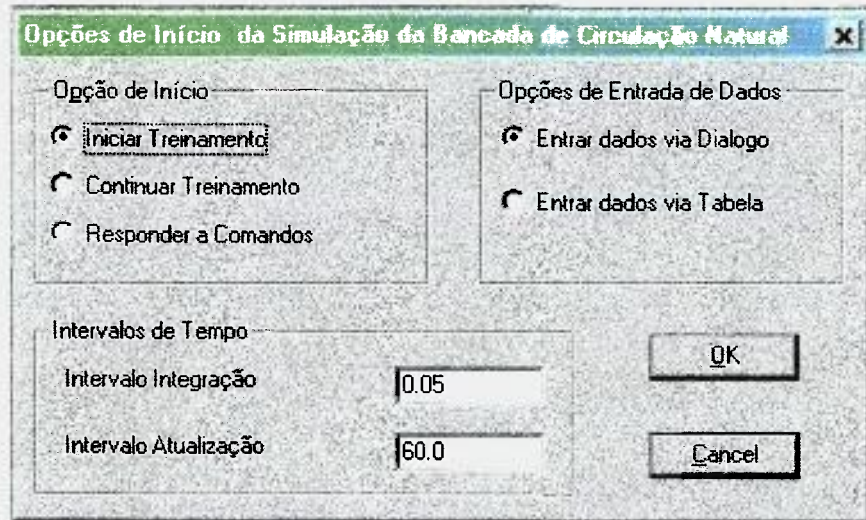


Figura A2.3 - Caixa de Diálogo Inicial.

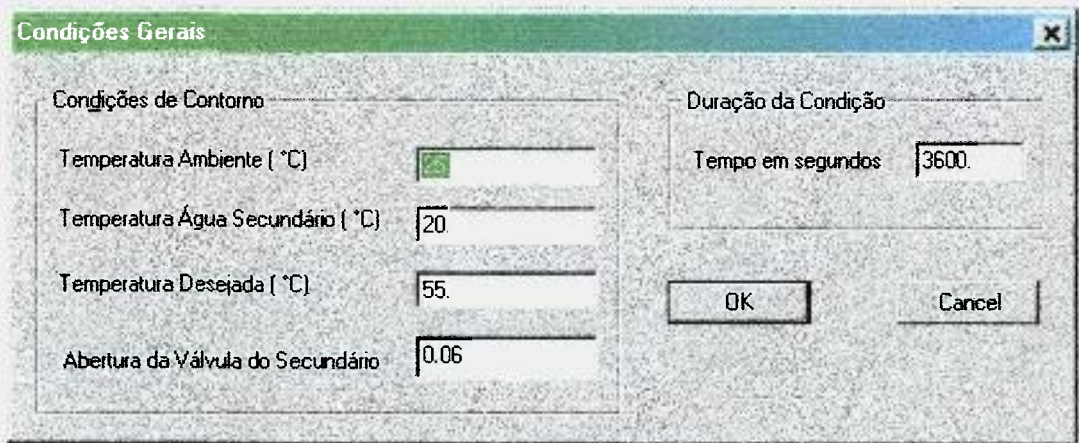


Figura A2.4 - Caixa de Diálogo de Condições Gerais.

REFERÊNCIAS BIBLIOGRÁFICAS

1. AKAZAWA, K.; KATO, K. (1990) Neural Network Model for Control of Muscle Force Based on the Size Principle of Motor Unit, *Proceedings of the IEEE*, v. 78, n. 9, p. 1531-1535, September 1990.
2. ALKON, D.L. (1983) *Learning in a Marine Snail*. Scientific American, v. 249, n. 1, p. 64-74, Jul. 1983.
3. AMARI, D.; WIDROW, B. (1990) *Neural Networks for Self-Learning Control Systems*. IEEE Control Systems Magazine, p. 18-23, April 1990.
4. AMARI, S.-I. (1990) Mathematical Foundations of Neurocomputing. *Proceedings of the IEEE*, v. 78, n. 9, p. 1443-1463, September 1990.
5. ANDERSON, J.A. (1968) *A Memory Model Using Spatial Correlation Functions*. Kybernetik, v. 5, p. 113-119.
6. ANDERSON, J.A.; ROSENFELD, E. (eds.) (1988) *Neurocomputing: Foundations of Research*. Cambridge: MIT Press.
7. ASADA, H.; SLOTINE, J.-J.E. (1986) *Robot Analysis and Control*. New York, N.Y.: John Wiley and Sons.
8. BAPTISTA F^o, B. D. (1996) *Relatório de Evolução do Projeto da Bancada de Circulação Natural*. IPEN-CNEN/SP, Jul. 96. (PED.RES.CNEN.024, RELT.001.R00).
9. BAPTISTA F^o, B. D., MACEDO, L. A. (1997) *Atualização do Projeto da Bancada de Circulação Natural*. IPEN-CNEN/SP, Dez. 97. (PED.RES.CNEN.024, RELT.004.R00).
10. BULLOCK, D.; CONTRERAS-VIDAL, J.L. (1993) *How Spinal Neural Networks Reduce Discrepancies Between Motor Intention and Motor Realization*. In: K.M. NEWELL; D.M. (Eds.). *Variability and Motor Control*. Human Kinetics Publ. (Champaign, ILL), Ch. 9, p. 183-221.
11. BULLOCK, D.; GROSSBERG, S. (1989) *VITE and FLETE: Neural Modules for Trajectory Formation and Postural Control*. In: W. A. Hersheberger (Editor). *Volitional Action*. Elsevier Science Publishers B.V. (North-Holland), Ch. 11, p. 253-297.
12. BULLOCK, D.; GROSSBERG, S. (1990) *Skill Development and Neural Networks for Position Code Invariance under Speed and Compliance Rescaling*. In: H. BLOCH; B.J. BERTENTHAL (Eds.). *Sensory-Motor Organizations and Development in Infancy and Early Childhood*. Kluwer Academic Publishers, p. 1-22.
13. BULLOCK, D.; GROSSBERG, S. (1990) *Spinal Network Computations Enable Independent Control of Muscle Length and Joint Compliance*. In: R. ECKMILLER (Editor). *Advanced Neural Computers*. Elsevier Science Publishers B.V. (North-Holland), p. 349-356.

14. CARNAHAN, B.; LUTHER, H.A.; WILKES, J.O. (1967) *Applied Numerical Methods*. New York, N.Y.: John Wiley and Sons.
15. CHEN, F-C (1990) *Back-Propagation Neural Networks for Nonlinear Self-Tuning Control*. IEEE Control Systems Magazine, p. 44-48, April 1990.
16. DELUCA, C. J.; LEFEVER, R.S.; MCCUE, M.P.; XENAKIS, A.P. (1982) *Controls Scheme Governing Concurrently Active Human Motor Units During Voluntary Contractions*. J. Physiol., v. 329, p. 129-142.
17. ECKMILLER, R. (1989) *Neural Nets for Sensory and Motor Trajectories*. IEEE Control Systems Magazine, p. 53-59, April 1989.
18. FRIESEN, W.O.; FRIESEN, J.A. (1994) *NeuroDynamix - Computer Models for Neurophysiology*. New York: Oxford University Press.
19. GALL, F.J.; SPURZHEIM, G. (1810). *Anatomie et physiologie du système nerveux en général, et du cerveau en particulier, avec des observations sur la possibilité de reconnoitre plusieurs dispositions intellectuelles et morales de l'homme et des animaux, para la configuration de leurs têtes*. Paris: Schoell.
20. GHEZ, C. (1991) *The Control of Movement*. In: KANDEL, E. R.; SCHWARTZ, J. H.; JESSEL, T.M. (Eds.). *Principles of Neural Science*. Prentice-Hall International Inc., 1991, Ch. 35, p. 533-547.
21. GOLDIN-MEADOW, S.; MYLANDER, C. (1998) *Spontaneous Sign Systems Created by Deaf Children in Two Cultures*. *Letter to Nature*, v. 391, p. 279, 1 Jan-26 Feb 1998.
22. GROSSBERG, S. (1967). Nonlinear Difference-Differential Equations in Prediction and Learning Theory. *Proceedings of the National Academy of Sciences, USA* 58, p.1329-1334.
23. GROSSBERG, S. (1969). *Embedding Fields: A Theory of Learning with Physiological Implications*. *Journal of Mathematical Psychology*, v. 6, p.206-239.
24. GUEZ, A.; EILBERT, J.L.; KAM, M. (1988) *Neural Network Architecture for Control*. IEEE Control Systems Magazine, p. 22-25, April 1988.
25. HANDELMAN, D.A.; LANE, S.H.; GELFAND, J.J. (1990) *Integrating Neural Networks and Knowledge-Based Systems for Intelligent Robotic Control*. IEEE Control Systems Magazine, p. 77-87, April 1990.
26. HEBB, D.O. (1949). *The Organization of Behavior*. New York: Wiley. Parcialmente reimpresso em Anderson e Rosenfeld (1988).
27. HERTZ, J.; KROGH, A.; PALMER, R.G. (1991) *Introduction to the Theory of Neural Computation*. Lecture Notes Volume I in the Santa Fe Institute Studies in the Sciences of Complexity: Addison-Wesley Publishing Company.

28. HEUSER, J.E.; SALPETER, S.R. (1979) *Organization of Acetylcholine receptors in Quick-frozen, Deep-etched, and Rotary-replicated Torpedo Membrane*. *J. Cell. Biol.*, v.82, p. 150-173.
29. HODGKIN, A.L.; HUXLEY, A.F. (1952) *A Quantitative Description of Membrane Current and its Application to Conduction and Excitation in Nerve*. *J. Physiol. (Lond.)*, v. 117, p. 500-544.
30. HOPFIELD, J.J. (1982) Neural Networks and Physical Systems with Emergent Collective Computational Abilities. *Proceedings of the National Academy of Science, USA* 79, 2554-2558. Reimpresso em Anderson e Rosenfeld (1988).
31. HUGUENARD, J.; McCORMICK, D.A. (1994) *Electrophysiology of the Neuron - An Interactive Tutorial*. New York: Oxford University Press.
32. HUNNS, D.M.; WAINWRIGHT, N. (1991) *Software-based Protection for Sizewell B: The Regulator's Perspective*. *Nuclear Engineering International*, p. 38-40, Sept. 1991.
33. JONES, L.K. (1990) Constructive Approximations for Neural Networks by Sigmoidal Functions. *Proceedings of the IEEE*, v. 78, n. 10, p. 1586-1589, October 1990.
34. KANDEL, E. R. (1989) *Genes, Nerve Cells, and the Remembrance of Things Past*. *J. Neuropsychiatry*, v. 1, p. 103-125.
35. KANDEL, E. R. (1991a) *Brain and Behavior*. In: KANDEL, E. R.; SCHWARTZ, J. H.; JESSEL, T.M. (Eds.). *Principles of Neural Science*. Prentice-Hall International Inc., 1991, Ch. 1, p. 5-17.
36. KANDEL, E. R. (1991b) *Cellular Mechanisms of Learning and the Biological Basis of Individuality*. In: KANDEL, E. R.; SCHWARTZ, J. H.; JESSEL, T.M. (Eds.). *Principles of Neural Science*. Prentice-Hall International Inc., 1991, Ch. 65, p. 1009-1031.
37. KANDEL, E. R. (1991c) *Nerve Cells and Behavior*. In: KANDEL, E. R.; SCHWARTZ, J. H.; JESSEL, T.M. (Eds.). *Principles of Neural Science*. Prentice-Hall International Inc., 1991, Ch. 2, p. 18-32.
38. KANDEL, E. R.; SCHWARTZ, J. H. (1982) *Molecular Biology of Learning: Modulation of Transmitter Release*. *Science*, 218, p. 433-443.
39. KANDEL, E. R.; SCHWARTZ, J. H. (1991) *Directly Gated Transmission at Central Synapses*. In: KANDEL, E. R.; SCHWARTZ, J. H.; JESSEL, T.M. (Eds.). *Principles of Neural Science*. Prentice-Hall International Inc., 1991, Ch. 11, p. 151-172.
40. KANDEL, E. R.; SIEGELBAUM, S.A.S.; SCHWARTZ, J. H. (1991) *Synaptic Transmission*. In: KANDEL, E. R.; SCHWARTZ, J. H.; JESSEL, T.M. (Eds.). *Principles of Neural Science*. Prentice-Hall International Inc., Ch. 9, p. 121.

41. KAWATO, M.; UNO, Y.; ISOBE, M.; SUSUKI, R. (1988) *Hierarchical Neural Network Model for Voluntary Movement with Application to Robotics*. IEEE Control Systems Magazine, p. 8-16, April 1988.
42. KELLY, J.P.; DODD, J. (1991) *Anatomical Organization of the Nervous System*. In: KANDEL, E. R.; SCHWARTZ, J. H.; JESSEL, T.M. (Eds.). *Principles of Neural Science*. Prentice-Hall International Inc., 1991, Ch. 19, p. 273-282.
43. KOHONEN, T. (1974). *An Adaptive Associative Memory Principle*. IEEE Transactions on Computers, C-23, p. 444-445, 1974.
44. KOHONEN, T. (1982). *Self-Organized Formation of Topologically Correct Feature Maps*. Biological Cybernetics, v.43, p. 59-69. Reimpresso em Anderson e Rosenfeld (1988).
45. KOLEN, J.F.; GOEL, A. K. (1991) Learning in Parallel Distributed Processing Networks: Computational Complexity and Information Content, *IEEE Transactions on Systems, Man, and Cybernetics*, v. 21, n. 2, p. 359-367, March/April 1991.
46. KUNG, S-Y.; HWANG, J-N. (1989) *Neural Network Architectures for Robotic Applications*. IEEE Transactions on Robotics and Automation, v. 5, n. 5, p. 641-657, October 1989.
47. KUPERSTEIN, M.; RUBINSTEIN, J. (1989) *Implementation of an Adaptive Neural Controller for Sensory-Motor Coordination*. IEEE Control Systems Magazine, p. 25-30, April 1989.
48. KUPFERMANN, I. (1991) *Learning and Memory*. In: KANDEL, E. R.; SCHWARTZ, J. H.; JESSEL, T.M. (Eds.). *Principles of Neural Science*. Prentice-Hall International Inc., 1991, Ch. 64, p. 997-1008.
49. MCCULLOCH, W.S.; PITTS, W. (1943) *A Logical Calculus of Ideas Immanent in Nervous Activity*, Bulletin of Mathematical Biophysics n. 5, p. 115-133, 1943.
50. MICROSOFT CORPORATION (1995) *Fortran PowerStation - Programmer's Guide*. Doc. No. DD64081-0995.
51. MINSKY, M.L.; PAPERT, S.A. (1969) *PERCEPTRONS*. Cambridge: MIT Press.
52. NATIONAL INSTRUMENTS (1995) *Instrumentation Reference and Catalogue - Test and Measurement Process Monitoring and Control*.
53. NATIONAL INSTRUMENTS (1995) *LabWindows/CVI - Visual Programming for Instrumentation - Programmer Reference Manual*. June 1995 Edition.
54. von NEUMANN, J. (1956) *Probabilistic Logics and the Synthesis of Reliable Organisms from Unreliable Components*. In: C. E. SHANNON, J. McCARTHY (Eds.). *Automata Studies*. Princeton: Princeton University Press, 1956, p. 43-98.
55. NGUYEN, D. H.; WIDROW, B. (1990) *Neural Networks for Self-Learning Control Systems*. IEEE Control Systems Magazine, p. 18-23, April 1990.

56. NIEMANN, G. (1950) *Maschinenelemente*, Springer-Verlag: OHG..
57. PARKER, D. (1982) *Learning-logic*. Invention Report S81-64, File 1, Office of Technology Licensing, Stanford University, Stanford, CA, Oct. 1982.
58. POGGIO, T.; GIROSI, F. (1990) Networks for Approximation and Learning. *Proceedings of the IEEE*, v. 78, n. 9, p. 1481-1497, September 1990.
59. PSALTIS, D.; SIDERIS, A.; YAMAMURA A.A. (1988) *A Multilayered Neural Network Controller*. IEEE Control Systems Magazine, p. 17-21, April 1988.
60. ROSENBLATT, F. (1959) *Two Theorems of Statistical Separability in the Perceptron*, In: *Mechanization of Thought Processes: Proceedings of a Symposium held at the National Physical Laboratory*, Nov. 1958, v. 1, p. 421-456, London: HM Stationery Office.
61. RUMELHART, HINTON; D.E. G.E.; WILLIAMS, R.J. (1985) *Learning Internal Representations by Error Propagation*. Institute for Cognitive Science, University of California at San Diego, La Jolla, CA, Sept. 1985. (ICS Report 8506)
62. SAKMANN, B.; NEHER, E. (eds.) (1983). *Single-Channel Recording*. New York: Plenum Press.
63. SPENCER, W.A.; THOMPSON, R.F.; NEILSON, D.R., JR. (1966) *Response Decrement of the Flexion Reflex in the Acute Spinal Cat and Transient Restoration by Strong Stimuli*. J. Neurophysiol., v. 29, p. 221-239.
64. STEVENS, F.C. (1994) *Cooperativity of Unreliable Neurons*. Current Biology, v. 4, n. 3, p. 268-269.
65. VIJUK, R., BRUSCHI, H. (1988) *AP600 offers a simpler way to greater safety, operability and maintainability*. Nuclear Engineering International, Advanced LWRs, p. 22-28, Nov. 1988.
66. WEISS, P.; HISCOE, H.B. (1948) *Experiments on the Mechanism of Nerve Growth*. J. Exp. Zool., 107:315-395.
67. WERBOS, P.J. (1974) *Beyond regression: New Tools for Prediction and Analysis in the Behavioral Sciences*. Cambridge, MA: Nov. 1974. Ph.D. dissertation, Committee on Appl. Math., Harvard Univ.
68. WIDROW, B.; HOFF, M.E. (1960) *Adaptive Switching Circuits*, In *1960 IRE WESCON Convention Record*, part 4, p. 96-104, New York: IRE.
69. WIDROW, B.; LEHR, M.A. (1990) 30 Years of Adaptive Neural Networks: Perceptron, Madaline, and Backpropagation. *Proceedings of the IEEE*, v. 78, n. 9, p. 1415-1442, September 1990.