

UNIVERSIDADE ESTADUAL DE CAMPINAS - UNICAMP

FACULDADE DE ENGENHARIA ELÉTRICA

DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

**REDES NEURAIS ARTIFICIAIS
PARA O CONTROLE DA MARCHA PRODUZIDA POR
ESTIMULAÇÃO ELÉTRICA NEUROMUSCULAR**

Por:

Francisco Antonio Sepulveda Inostroza

Orientador:

Dr. Alberto Cliquet Júnior

Tese de doutorado apresentada à
Faculdade de Engenharia Elétrica da
Unicamp em 28 de Fevereiro de 1996.

Campinas, SP

Este exemplar corresponde à redação final da tese
defendida por FRANCISCO ANTONIO SEPULVEDA
LAVS 720-71 e aprovada pela Comissão
Julgadora em 28/02/96.
Alberto Cliquet Jr.
Orientador

UNIDADE	BC
N.º CHAMADA:	T/UNICAMP
	SE63R
V.	
TÍTULO	27426
PROJ.	667/96
C.	015
PREÇO	R\$ 11,00
DATA	25/04/96
N.º CPD	

CM-00087071-2

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

Se63r

Sepulveda Inostroza, Francisco Antonio

Redes neurais artificiais para o controle da marcha
produzida por estimulação elétrica neuromuscular /
Francisco Antonio Sepulveda Inostroza.--Campinas, SP:
[s.n.], 1996.

Orientador: Alberto Cliquet Júnior.

Tese (doutorado) - Universidade Estadual de Campinas
Faculdade de Engenharia Elétrica.

1. Redes neurais (Computação). 2. Controle
automático. 3. Estimulo neural. 4. Membros inferiores.
I. Cliquet Júnior, Alberto. II. Universidade Estadual de
Campinas. Faculdade de Engenharia Elétrica. III. Título.

*Sinto.
Logo,
não importa se eu penso
ou se existo.*

f.s.

AGRADECIMENTOS

Agradeço em primeiro lugar à família Sepúlveda Inostroza, que, apesar de espalhada pelo mundo tem me dado forte apoio nas horas de necessidade.

Agradeço também ao meu orientador Dr. Alberto Cliquet Jr. por ter me proporcionado a liberdade de trabalho que me apraz e sempre desejo.

Contribuíram de forma acadêmica e fraternal muitos membros do Departamento de Engenharia Biomédica e do curso de Engenharia em Computação. Dentre eles, cito com agradecimento sincero a Antônio Quevedo, François Sovi, e Luciano de Mancilha. Este último também contribuiu com um trabalho de iniciação científica (bolsista CNPq/Unicamp) relacionado ao uso de redes neurais para o reconhecimento de comandos verbais, projeto de importância para o trabalho com lesados medulares. Também em caráter de iniciação científica, Jorge Socolowski (bolsista SAE-Unicamp) reproduziu alguns dos resultados com duas das redes neurais do sistema teórico discutido nesta tese.

Agradeço a hospitalidade e apoio dados pelo Dr. M. H. Granat e o grupo de estimulação elétrica da Unidade de Bioengenharia, Universidade de Strathclyde, Glasgow. Nesta instituição, numa visita colaborativa, o autor introduziu o uso experimental de redes neurais artificiais no controle da estimulação elétrica neuromuscular. Em particular, resalto a amizade e ajuda técnica dadas por Anand D. Pandyan, Ekaterini Bourgani, Gavin Devaney, Ian Thomas, Nicos Moursselas, e Yong Yang.

Agradeço aos Drs. Jaime Szajner, Marcio de Andrade Netto, Jocelyn Freitas de Bennaton, e Donizetti Honorato pela participação em minha banca examinadora.

Agradeço também aos(às) cidadãos(ãs) brasileiros(as) que pagam seus impostos com honestidade. Graças a eles(as), foi possível o financiamento desta tese através do CNPq.

Finalmente, gostaria de expressar meu sincero agradecimento aos três pacientes que participaram deste projeto. Aprecio muito a disposição deles e sua paciência com pesquisadores desta área que ainda está por dar-lhes algo realmente útil.

RESUMO

Neste Trabalho, foi explorada a aplicação de redes neurais artificiais para o controle da marcha por meio de estimulação elétrica neuromuscular em pacientes com lesão medular. Para tanto, dois caminhos independentes foram seguidos, um teórico, e outro experimental.

No estudo teórico, foi preparada uma rede neural de três camadas para modelar as transformações sensório-motoras segmentares ocorridas durante a marcha num plano. As entradas para a rede neural foram proporcionais aos ângulos de flexão e extensão do quadril, joelho e tornozelo, e à componente vertical da força de reação do solo. As saídas foram proporcionais ao nível de atividade em cinco músculos essenciais à produção da marcha vista num plano sagital. Os resultados de simulações com várias estruturas neurais diferentes indicam uma melhora no controle do movimento quando a última saída é incluída no vetor de entrada atual. Além disso, o controle da marcha parece ser melhor quando executado por duas redes independentes (uma para a fase de apoio da marcha, e outra para a fase de balanço) do que quando uma única rede é usada para o controle de todo o ciclo da marcha. Por outro lado, nenhuma melhora foi observada com a inclusão de recursão no algoritmo de aprendizado, memória de entradas passadas, intraconectividade na camada escondida, conectividade seletiva entre as camadas escondida e de saída, ou do uso de derivadas dos sinais de entrada e saída.

No trabalho experimental, uma rede neural de três camadas foi usada no controle adaptativo da geração da fase de balanço. Dois sistemas foram testados. No Sistema 1, na entrada da rede neural foram usados os sinais dos goniômetros de joelho e tornozelo. Já no Sistema 2, os ângulos do quadril e joelho foram considerados. Em ambos os casos, as saídas foram proporcionais ao aumento ou diminuição da largura de pulso aplicada. A estimulação foi aplicada no nervo femoral e no nervo peroneal comum. A rede neural foi treinada de modo 'on-line' e 'off-line'. Para avaliar o desempenho dos sistemas, varias combinações de

largura de pulso foram preestabelecidas. A resposta do sistema (movimentos produzidos) foi então comparada a um ciclo de referência obtido para cada sessão de testes. O treinamento 'on-line' consistiu na aplicação de punição e reforço positivo de modo seletivo. Tanto o esquema 'off-line' como o esquema 'on-line' incluíram o uso de um algoritmo de retropropagação acelerado. Ao comparar o desempenho dos Sistemas 1 e 2, o primeiro parece ser melhor. Além disso, o desempenho da rede durante o treinamento 'on-line' é melhor que o da rede treinada apenas 'off-line'. De acordo com alguns resultados, um protótipo no Sistema 1 foi preparado e usado na geração do ciclo completo da marcha em um paciente com lesão medular.

ABSTRACT

This work consisted in the application of artificial neural network algorithms for control of gait generated by NeuroMuscular Electrical Stimulation (EENM) in spinal cord injured subjects. Two independent approaches were attempted - namely, a theoretical, and an experimental approach.

In the theoretical study, a three-layered neural network was set up to model the segmental sensorimotor transformations involved in level walking. Network inputs were proportional to hip, knee, and ankle flexion/extension angles, and to vertical ground reaction forces. The output signal was proportional to the activity level of five muscles essential to gait production as seen from the sagittal plane. Results from simulations for various network structures indicate that motion control improves when the latest output is used as part of the input vector. Also, it appears that motion control is better when done with two independent networks (one for the stance phase of gait and another for the swing phase) than with a single network for the entire gait cycle. Further, inclusion of explicit recursion in the learning algorithm, recall of previous inputs, hidden layer intraconnectivity, selective hidden layer to output layer connectivity, and the use of signal derivatives all resulted in no improvement in the simulated gait control.

In the experimental approach, a three-layered artificial neural network was used for adaptive control of the swing phase only. Network inputs consisted of knee and ankle goniometer signals for System 1, and knee and hip angular data for System 2. Controller output was proportional to changes in applied NMES pulse width (PW). Stimulation was applied to the left femoral and common peroneal nerves. The neural networks were trained off-line and on-line. Network performance was assessed by applying a number of different stimulation PWs and later comparing the resulting motion to a sample good step observed during the same test session. On-line training consisted of negative and positive re-

enforcement applied at chosen times. Both on-line and off-line training algorithms included an enhanced back-propagation scheme. Performance evaluation results favour the use of System 1 over System 2. Also, network performance during on-line learning is better than that of a network submitted to off-line learning only. Then, according to some of the results, a prototype based on System 1 was set up and used for generation of the entire gait cycle in one spinal subject.

ÍNDICE

	Página
<i>Agradecimentos</i>	<i>I</i>
<i>Resumo</i>	<i>II</i>
<i>Abstract</i>	<i>VI</i>
<i>Abreviações</i>	<i>i</i>
<i>Capítulo 1:</i> <u>Introdução: Reabilitação da Marcha em Pacientes com Lesões Medulares</u>	<i>1</i>
<i>Capítulo 2:</i> <u>Redes Neurais Artificiais e o Controle da Marcha</u>	<i>18</i>
<i>Capítulo 3:</i> <u>Simulações com Redes Neurais Artificiais Para a Produção da Marcha</u>	<i>40</i>
<i>Capítulo 4:</i> <u>Sistema Experimental</u>	<i>54</i>
<i>Capítulo 5:</i> <u>Resultados: Sistema Teórico</u>	<i>74</i>
<i>Capítulo 6:</i> <u>Resultados: Sistema Experimental</u>	<i>89</i>
<i>Capítulo 7:</i> <u>Discussão</u>	<i>104</i>
<i>Capítulo 8:</i> <u>Conclusão e Sugestões Para Trabalhos Futuros</u>	<i>114</i>
<i>Bibliografia</i>	<i>116</i>
<i>Apêndice A:</i> <u>Diagrama da Retropropagação Instantânea</u>	<i>126</i>

LISTA DE ABREVIACES

ABREVIACO	COMENTRIO
A	fase de Apoio
B	fase de Balano
CC	Ciclo Completo da marcha
crc	Coefficiente de Correlaco
EENM	Estimulaco Eltrica NeuroMuscular
EMG	EletroMioGrafia
FR	Fora de Reaco vertical
ID	ndice de Desempenho
IE	Intraconectividade na camada Escondida
LP	Largura de Pulso
MN	MotoNeurnio
MQE	Mdia dos Quadrados dos Erros
P	Punio
R	Reforo positivo
\mathcal{R}	taxa de aprendizado
RR	algoritmo com Recurso
SL	conectividade Seletiva entre as camadas escondida e de sada
TSA	Teste Sem Adaptao sinptica
W	pesos sinpticos

CAPÍTULO 1

INTRODUÇÃO: REABILITAÇÃO DA MARCHA EM PACIENTES COM LESÕES MEDULARES

1.1 A MARCHA HUMANA

Três milhões e meio de anos atrás, surgia o bipedalismo entre os primatas. Curiosamente, isto aconteceu muito antes do aparecimento do *Homo Habilis*. Pensava-se (e muitos ainda insistem neste ponto) que o bipedalismo surgira como decorrência da necessidade (e da habilidade) de trabalhar ferramentas, sendo esta associada à rápida multiplicação no volume cerebral do *Hominídeo* com respeito a outros primatas. No entanto, há forte evidência (Tuttle, 1990) de que o bipedalismo primata precedeu o rápido crescimento da massa encefálica (e suas consequências) em mais de um milhão de anos! O que teria levado ao aparecimento do bipedalismo, por outro lado, ainda é foco de debate, apesar de que fatores climáticos estão provavelmente entre os agentes causadores (Calvin, 1990; Gribbin e Gribbin, 1990). Sabe-se sim, muito sobre os benefícios decorrentes da liberação das mãos e da posterior ereção postural. O *Hominídeo* gradualmente ganhou mais velocidade de locomoção, aprendeu a caçar, e finalmente aprendeu a construir abrigos cada vez mais robustos. Pode-se argumentar, inclusive, que de nada teria servido o crescimento encefálico se este tivesse aparecido antes do bipedalismo: a nova espécie possivelmente não teria sobrevivido.

O fato é que a marcha bípede trouxe também uma série de complexidades referentes ao controle da locomoção. Já não basta a propulsão (tanto vertical como horizontal). A

questão da estabilidade e equilíbrio ganhou importância adicional. Tal é o problema, que as minúcias da marcha humana têm escapado às investidas de pesquisadores desde os tempos remotos em que se acreditava no *Homúnculo*, nos séculos XVI e XVII (Inman *et al.*, 1981). Isto dificulta a tarefa daqueles que querem reproduzir tais movimentos, seja em robôs ou em seres humanos.

No entanto, alguns conceitos fundamentais têm emergido de estudos biomecânicos (nesta tese, serão abordados somente aspectos da marcha essenciais ao entendimento do trabalho; para uma análise mais profunda sobre o tema, o leitor deve consultar Vaughan *et al.*, 1992, Winter, 1987, e Brooks, 1986). De acordo com as pesquisas, quatro elementos constituem a forma mais básica da marcha humana (Solomonow, 1992):

1. Postura ereta
2. Balanço de uma perna
3. Tração simultânea com a perna contralateral
4. Manutenção do equilíbrio e apoio durante o movimento

Além destes fatores, é importante que exista equilíbrio e apoio durante a permanência em pé, possivelmente com um gasto energético mínimo.

O balanço de uma perna exige que haja pelo menos flexão do quadril, mas implica também em flexão do joelho e tornozelo em pessoas normais (além dos movimentos nos membros superiores). Caso somente o quadril seja flexionado, o deslocamento lateral do centro de massa terá que ser maior para permitir a liberação do pé ipsilateral e o posterior contato do calcanhar com o solo, no fim do balanço. Isto reduz a estabilidade do movimento. Ao mesmo tempo, para que exista a tração na perna contralateral, deve ocorrer a extensão do quadril e joelho e flexão plantar do tornozelo na perna em questão. Para a manutenção do equilíbrio, o centro de massa deve situar-se de tal forma que a sua projeção no solo se

localize entre os dois pés. Qualquer fuga do centro de massa desta região pode causar uma queda se não houver uma correção suficientemente rápida, o que nem sempre é possível.

Apesar da aparente simplicidade dos movimentos aqui mencionados, o número de grupos musculares necessários para a execução destes pode passar dos setenta. Além disso, a relação entre o sinal alpha-motoneural, a atividade muscular, e o movimento resultante é até hoje desconhecida (mais sobre isto no Capítulo 2).

Estes fatos tornam-se de suma importância especialmente quando se quer restaurar a locomoção em pessoas portadoras de patologias. Ora, se tão pouco é conhecido sobre a geração normal da marcha, como seria possível reproduzir o movimento?

No restante desta tese, serão apresentados alguns esforços par restaurar a locomoção especificamente em pacientes com lesões medulares. Antes disso, no entanto, cabe um rápida discussão sobre o sistema medular, permitindo uma breve apresentação da complexidade do problema.

1.2 MEDULA ESPINHAL

1.2.1 A Medula e a Produção de Movimentos

A habilidade da medula espinhal em controlar movimentos sem interferência supraespinhal baseia-se fundamentalmente numa estrutura neural que lhe permite ativar (com variada intensidade) e desativar motoneurônios (MNs) alfa e gama. Todos os MNs de um núcleo (“motoneuron pool”), seja qual for o tamanho destes, recebem terminações aferentes de todos os fusos no músculo enervado (para uma abordagem mais básica e introdução aos termos aqui usados, o leitor é referido a Guyton, 1986, Shepherd, 1988, ou Kandel e Schwartz, 1985). Quando um fuso muscular manda um sinal para os centros espinhais, a descarga (via fibras Ia) tem efeitos diferentes em MNs de tamanhos diferentes (Brooks,

1986). Em células menores, as terminações aferentes se encontram mais próximas umas das outras, produzindo uma corrente maior que em MNs de grande porte. Além disso, MNs menores têm membranas com maior resistência (Jack *et al.*, 1983). O resultado, de acordo com a lei de Ohm, é um potencial pós-sináptico excitatório (PPSE) maior em células menores (Aidley, 1989).

Tudo isto seria irrelevante para este trabalho, não fosse o fato de que o principal fator para o recrutamento de reflexos é justamente o PPSE. O limiar de excitação em MNs menores é atingido antes, não por que o limiar nestes seja menor (o que é verdade), mas por que o PPSE incidente é maior. Isto resulta no recrutamento muscular de acordo com o tamanho do MN associado, o chamado princípio de Henneman (1981). Vale enfatizar que este princípio se aplica somente quando a estimulação dos MNs provem de meios endógenos, seja ela em reflexos ou mesmo em atividade voluntária. Caso a estimulação seja feita por eletrodos, por exemplo, ocorre o fenômeno inverso: Fibras maiores têm um limiar de excitação menor.

O recrutamento segundo o tamanho das fibras permite contrações musculares mais suaves e energeticamente mais eficientes (em geral, não há o recrutamento desnecessário de unidades motoras de grande porte). Este fenômeno é um dos de mais difíceis de se reproduzir num sistema artificial para contração muscular. Outros fatores incluem a inibição simultânea e seletiva de unidades motoras antagonistas por meio de interneurônios medulares.

De fato, a riqueza do processamento espinhal é tal, que as características mais rudimentares da marcha não requerem interferência de centros supraespinhais. Trabalhos clássicos desenvolvidos com gatos e outros vertebrados espinalizados levaram à noção de geradores centrais de padrões (GCP). GCPs são circuitos neurais, localizados ou distribuídos, capazes de gerar contrações musculares rítmicas e coordenadas. Este conceito provém de modelos como os “half centers” desenvolvido por George Brown no início do século (Shepherd, 1988), e de trabalhos como o de G. Szeckely (1968). Nestes trabalhos,

gatos com secção medular (em vários níveis) puderam caminhar numa esteira mecânica (Wetzel e Stuart, 1976). O movimento foi iniciado de várias maneiras, entre elas mediante o simples movimento da esteira. Os suecos Grillner e Zangger (1984) mostraram que um gato com secção torácica intermediária pode executar a marcha com as pernas traseiras, e pode inclusive ajustar a velocidade dos movimentos quase simultaneamente com variações na velocidade da esteira. Mais surpreendente ainda, é o fato de que em gatos com secção no mesencéfalo, os sinais eletromiográficos (dos músculos das pernas) durante a marcha têm um comportamento temporal muito parecido ao dos sinais obtidos de gatos sem lesão.

Claro, nem tudo acima pode aplicar-se a seres humanos. Mas, como no gato, uma marcha rudimentar pode ser produzida por GCPs também em seres humanos. Estes GCPs são adquiridos tanto na filogênese humana como nos estágios mais importantes do aprendizado motor. A estrutura destes circuitos neurais, no entanto, não é rígida. Ela mantém um grau elevado de adaptação mesmo em adultos.

Um modelo simples de um circuito neural para a produção da marcha será apresentado mais adiante nesta tese (Sistema Teórico, Capítulo 3). De qualquer forma, estes são tópicos a serem estudados mais a fundo tanto por aqueles que estudam a produção de movimentos como por aqueles que tentam restaurá-la.

1.2.2 Sobre Lesões Medulares

Nos Estados Unidos, a incidência anual de lesões medulares sérias chega à marca de 500 por milhão de habitantes (Capildeo e Maxwell, 1984), sendo que a maior taxa de incidência ocorre entre homens de 19 a 25 anos de idade. Estes pacientes não têm afetada somente a capacidade de locomoção; eles sofrem alterações também em funções mais básicas como controle da temperatura e da evacuação por via anal e urinária, dependendo do nível da

lesão (Guttman, 1976). Outros problemas associados à lesão medular incluem contraturas, osteoporose, perda de proprio e exterocepção, e disfunção sexual.

Alguns destes fatores dificultam a restauração de movimentos. Contraturas, por exemplo, podem inclusive causar dores que impedem o movimento (Perry, 1981). A osteoporose, por outro lado, compromete o uso das pernas e pode resultar em fraturas (Popovic, 1992; Lukert, 1982). Existem algumas tentativas para reduzir a osteoporose em pacientes medulares através de estimulação elétrica esporádica (Philips *et al.*, 1984), mas estas têm mostrado sérias limitações. Já a estimulação crônica iniciada logo após a lesão, tem apresentado resultados promissores, ainda que subjetivos (Popovic, 1992).

No tocante à perda de locomoção, há três possíveis caminhos para amenizar o problema:

1. Cura da enfermidade, ou seja, regeneração medular,
2. assistir o paciente por meio de aparelhos, e
3. facilitar a locomoção através de modificações no meio ambiente.

O primeiro item está fora de questão, pelo menos por enquanto (Philips, 1991), apesar de resultados promissores obtidos por alguns pesquisadores (Bjorklund e Stenevi, 1979; Purves *et al.*, 1981; Purves, 1988). O segundo item inclui o uso de órteses e próteses de vários tipos, incluindo o uso de estimulação elétrica neuromuscular. Este item é um dos principais focos da engenharia de reabilitação e será discutido em mais detalhes nas sessões abaixo. O terceiro item, adaptação do meio ambiente, implica em transformações que muitas vezes são consideradas desnecessárias pelo público em geral. Por exemplo, nesta mesma Universidade não há elevadores nos prédios onde são dadas aulas. Isto reduz em muito as possibilidades de uma pessoa com lesão medular, seja ela aluno(a) ou funcionário(a), mesmo se pesquisas já tivessem alcançado bons resultados nos itens 1 e 2 acima. De qualquer forma, a negligência com respeito ao item 3 não existe apenas no Brasil. Para resolver o problema, seria necessária a colaboração de engenheiros civis, de meio ambiente, e biomédicos, de médicos, e

de pacientes. Com certeza não é tarefa fácil, mas merece menção aqui por estar intimamente ligada ao problema que se quer amenizar.

Ao ter a locomoção restaurada, o paciente medular tem também outros benefícios. Ao manter-se em pé e movimentar-se, o paciente ganha uma redução da osteoporose, alívio temporário da pressão em áreas sobrecarregadas (como as nádegas), redução de contraturas e da espasticidade, possível prevenção da obesidade, condicionamento cardiovascular e pulmonar, e melhora na função renal e da bexiga (Guttman, 1976; Rowley e Edwards, 1987; Heller, 1992). É desnecessário dizer que a locomoção também tem efeitos psicológicos positivos no paciente medular.

Por estas razões, pesquisadores em engenharia de reabilitação não têm medido esforços para restaurar a locomoção em pacientes medulares. Alguns destes esforços serão discutidos abaixo.

1.3 MARCHA ASSISTIDA EM PACIENTES MEDULARES

Ao produzir uma órtese ou prótese, o pesquisador deve considerar cinco fatores de extrema importância (Stallard *et al.*, 1989; Heller, 1992):

1. Independência (ligar e desligar o aparelho, sentar-se e ficar de pé, e colocar e tirar o aparelho, tudo sem a ajuda de terceiros).
2. Baixo gasto energético (do paciente).
3. Aparência aceitável (tanto do aparelho como da marcha produzida).
4. Sistema confiável (seguro e que realmente funcione quando for ativado).
5. Baixo custo financeiro.

O autor adicionaria a esta lista itens referentes ao fácil uso, transporte, e manutenção do sistema.

O grau de importância de cada um dos fatores acima, varia de um paciente para outro. Por exemplo, o consumo energético pode não ser problema para um paciente jovem, ativo, e com uma lesão de nível baixo. Já o item cinco é provavelmente unanimemente importante, especialmente em países onde as fontes de capital são escassas.

Os tipos básicos de marcha obtida com a assistência de aparelhos são dois: a marcha recíproca, e a marcha de balanço (Bromley, 1985). A marcha recíproca é a que mais se assemelha à marcha normal. Nela, o paciente movimenta as pernas e as muletas de forma alternada. Cada elemento (dentre duas pernas e duas muletas) é movimentado individualmente, ficando três dos elementos (duas pernas e uma muleta, ou duas muletas e uma perna) em contato com o solo. Quando as muletas são movimentadas simultaneamente, mas as pernas de forma alternada, a marcha é considerada do tipo recíproca degenerada.

A marcha de balanço pode ser dividida em cinco sub-tipos (serão usados os termos em inglês por não haver uma tradução aceitável para o português): ‘swing to’, ‘drag to’, ‘swing from’, ‘swing through’, e ‘wheeling’ (Heller, 1992). A marcha ‘swing to’ é a mais usada. Nela, o paciente coloca ambas as muletas apoiadas à sua frente; logo o paciente, apoiando-se nas muletas, balança seu corpo até que as duas pernas alcancem as muletas. A marcha ‘drag to’ ocorre quando o paciente, ao tentar o ‘swing to’, não consegue erguer seu corpo e acaba por arrastar suas pernas até as muletas. Na marcha do tipo ‘swing from’ (raramente usada), ao contrário, os pés são colocados à frente das muletas, que são posteriormente levadas até a posição das pernas. A locomoção do tipo ‘swing through’ é a mais rápida de todas as opções para o paciente. Nela, o paciente coloca as muletas à sua frente, posteriormente balançando o corpo para a frente até que as pernas se situem anteriormente às muletas (e não adjacentes às muletas, como é o caso no ‘swing to’). Então, o paciente, apoiado agora nas pernas, novamente traz as muletas para a frente do corpo,

completando o ciclo. 'Wheeling' ocorre quando o paciente movimenta-se de forma similar ao 'swing through', mas com movimentos alternados das pernas. Este tipo de marcha requer que o paciente tenha algum controle de tronco e quadril. Em comparação com o 'swing through', a marcha 'wheeling' proporciona maior deslocamento por ciclo de movimento, mas o ciclo é mais lento e cansativo.

Tendo estes fatores em mente, segue agora uma breve abordagem dos aparatos usados para assistir a marcha em pacientes medulares.

1.3.1 Muletas

Muletas têm sido usadas por milhares de anos. Entretanto, pouco mudou na sua confecção. Tradicionalmente, o apoio nas muletas recai na região das axilas, o que pode causar complicações como trombose na artéria axilar (Brooks e Fowler, 1964) ou compressão do nervo radial (Rudin e Levine, 1951). Isto levou ao popular, e relativamente recente, uso da muleta com apoio na região do antebraço, próximo ao cotovelo. Também surgiu a chamada muleta 'canadense', que transfere o apoio para a região do bíceps. Esta última dá maior estabilidade que a muleta com apoio no antebraço. Ambas, no entanto, dão menos estabilidade ao paciente do que a tradicional muleta axilar (Stallard *et al.* 1978). De qualquer forma, os três tipos de muletas (e vários tipos de andadores) são usados por pacientes medulares em conjunto com outros aparelhos.

1.3.2 Órtese KAFO

A sigla KAFO vem do inglês 'Knee-Ankle-Foot-Orthosis' ('órtese de joelho, tornozelo, e pé'). Esta órtese mantém fixos o tornozelo (na posição neutra) e o joelho (em extensão completa). Um paraplégico sem controle do quadril pode manter-se em pé com uma

KAFO, ficando ele com o quadril projetado levemente para a frente, a chamada postura em 'C'. Para caminhar, o paciente pode adotar uma marcha tanto recíproca como de balanço. A qualidade da marcha com KAFO depende do nível da lesão medular. Segundo Alvarez (1985), para que a marcha com esta órtese seja boa, o paciente deve ter alguma propriocepção no quadril e um pouco de controle do tronco por meio do *latissimus dorsi* e dos músculos abdominais. Isto implica uma lesão à nível T12, ou mais abaixo. Caso a lesão seja um pouco mais alta, o quadril deve também ser restringido pela órtese, resultando numa HKAFO (o H refere-se ao quadril, ou 'hip').

1.3.3 Órtese RGO

No início dos anos setenta, foi desenvolvida uma órtese do tipo HKAFO que tinha conexões entre o quadril esquerdo e o direito por meio de cabos (Scruton, 1971). Isto permitiu a produção de uma marcha recíproca mesmo com uma órtese (flexão num quadril causa extensão no outro). Mais tarde (Douglas *et al.*, 1983), foi produzida a RGO ('Reciprocal Gait Orthosis', ou órtese para marcha recíproca). A RGO é basicamente uma KAFO com suporte torácico e uma fita pélvica. Esta órtese, já na versão original, tinha um mecanismo de desacoplamento entre os quadris, para facilitar o vestir e tirar da órtese. Na RGO, os movimentos do quadril limitam-se ao plano sagital.

Uma variação da RGO é a HGO ('Hip Guidance Orthosis', ou órtese com guia de quadril), também conhecida como 'ORLAU Parawalker' (Rose, 1979). Nela, dobradiças nos quadris também limitam o movimento ao plano sagital, mas não há o acoplamento (e a consequente reciprocidade) entre os quadris.

Tanto a HGO como a RGO permitem caminhar ao paciente com lesão torácica. Entretanto, ambas possuem tal número de elementos mecânicos, especialmente na região do quadril, que dificultam muito a execução de tarefas diárias como o vestir e tirar da órtese e o

uso do vaso sanitário (para uma abordagem mais completa das vantagens e desvantagens destas e outras órteses, o leitor deve consultar Solomonow, 1992, e Heller, 1992).

O uso das órteses acima pode ser complementado pela estimulação elétrica neuromuscular, a ser discutida logo abaixo. A combinação das duas técnicas resulta nos chamados sistemas híbridos (veja a seção 1.5), e tem dado resultados animadores em alguns casos (Cliquet *et al.*, 1986, 1989; Cliquet, 1992a, 1992b).

1.4 ESTIMULAÇÃO ELÉTRICA NEUROMUSCULAR (EENM):

NOCÕES GERAIS

1.4.1 História

O uso da estimulação elétrica para reativar a contração muscular provavelmente teve início por volta de 1760, no trabalho de Luigi Galvani. Antes disso, algumas tentativas já haviam sido feitas, como as 'milagrosas' contrações produzidas, em músculos paralisados, pelo versátil Benjamin Franklin já em 1757 (Hambrecht, 1992). Mas foi Galvani quem concebeu a idéia de que a eletricidade também participa em contrações normais (indo mais longe, Galvani provou que músculos e nervos produzem sua própria descarga elétrica). No entanto, no século XVIII existiam somente fontes de eletricidade estática. Estas produziam a contração muscular somente por um curto período, logo após o fechamento do circuito.

Cem anos se passaram até que a invenção do estimulador farádico (por volta de 1855) permitisse a contração muscular controlada e prolongada. Entretanto, o uso da estimulação elétrica neuromuscular (EENM) para restaurar a perda de movimentos em seres humanos, só ocorreu quatorze anos após a invenção do transistor. Em 1960, Kantrowitz usou EENM para estimular os músculos glúteos e o quadríceps num paciente paraplégico. Com este sistema, o paciente pôde levantar-se da cadeira de rodas e pôde manter-se em pé por alguns minutos

(Hambrecht, 1992). Na mesma época, Liberson e seus colaboradores (1961) aplicaram EENM no nervo peroneal de um paciente hemiplégico, para melhorar a dorsiflexão durante a marcha. O sistema de Liberson tinha um interruptor na sola do pé. Através deste interruptor, a estimulação ocorria somente quando o pé era erguido, no início da fase de balanço. Este aparato, entretanto, apresentou problemas relacionados à localização dos eletrodos (sério problema, ainda hoje), quebra dos cabos dos eletrodos, e irritação da pele. Com respeito à marcha, por outro lado, todos os pacientes que usaram este sistema tiveram alguma melhora na locomoção (Hambrecht, 1992).

A partir do anos setenta, inúmeros trabalhos têm sido realizados nesta área. O progresso, entretanto, tem sido lento. Uma discussão sobre as falhas e sucessos obtidos por pesquisadores será apresentada nas próximas sessões.

1.4.2 Candidatos à EENM

Para que a EENM tenha algum sucesso, o paciente deve ter, em primeiro lugar, preservadas as estruturas neurológicas periféricas (pelo menos parcialmente). Isto se deve ao fato de que, na EENM, são usados pulsos curtos e de baixíssima corrente, o que produz excitação especialmente de nervos, e raramente de músculos. O paciente também deve ter espasticidade moderada, osteoporose reduzida, e ausência de contraturas nas juntas (Popovic, 1992; Peckham e Keith, 1992). No caso da restauração da marcha, o paciente em potencial deve também poder controlar seu equilíbrio e postura com a ajuda dos membros superiores.

Geralmente, não devem ser considerados para tratamento com EENM pacientes com problemas sérios de ordem pulmonar e cardiovascular, e com osteoporose.

1.4.3 Eletrodos

A EENM é aplicada de duas formas básicas. Na estimulação direta, o sinal é aplicado no motoneurônio alfa (ou, mais precisamente, num feixe destes). Na estimulação indireta, reflexos são produzidos mediante a estimulação de fibras cutâneas aferentes. Em ambos os casos, três tipos de eletrodos podem ser usados: de superfície, percutâneos, e implantados.

Eletrodos de superfície são colocados na pele próximos ao ponto motor desejado. A vantagem destes eletrodos é que, como implica o nome, eles são não-invasivos. Por outro lado, estes eletrodos têm que ser colocados e retirados pelo menos diariamente, o que pode causar irritações na pele. Eles também sofrem mudanças na impedância (resultado da perda de água na interface com a pele) durante uma mesma sessão, exigindo incrementos na corrente e/ou tensão aplicada. Outro problema está relacionado à dificuldade de se estimular um grupo pequeno de músculos (por menor que seja a área dos eletrodos) e a impossibilidade de se estimular músculos profundos. Apesar destes problemas, os eletrodos de superfície são os mais usados na atualidade devido a seu baixo custo e ao relativamente baixo número de complicações por ele causadas.

Os eletrodos percutâneos são colocados de forma intramuscular, mediante injeção ou simplesmente com as mãos (tomadas as devidas medidas profiláticas). Em comparação aos eletrodos de superfície, os eletrodos percutâneos tem maior seletividade muscular, permitem a estimulação de músculos profundos, e requerem correntes menores. Segundo alguns pesquisadores, a incidência de infecções na região de aplicação é mínima (Sete casos de infecção, num total de 969 eletrodos implantados, num período de 36 meses), mas a taxa de quebra dos eletrodos é alta (70% após um ano) (Marsolais e Kobetic, 1987).

Para simular o processo de recrutamento, ainda que a grosso modo, eletrodos implantados têm que ser usados. Com este objetivo, Thoma *et al.* (1987) estimularam os nervos

femoral e gluteal através de eletrodos epineurais. Este sistema tinha quatro eletrodos colocados ao redor de cada nervo, os quais eram ativados independentemente um do outro. Com isto, foi reduzida a rápida fadiga muscular normalmente produzida pela EENM. Recentemente, eletrodos foram implantados diretamente nas raízes medulares para restaurar a evacuação voluntária da bexiga (Rushton, 1990). Para restaurar a marcha, entretanto, a escolha das raízes essenciais, e a complexa sequência de estimulação destas estão sendo pesquisadas somente agora (Popovic, 1992). Há ainda problemas mais sérios que impedem o uso de sistemas implantados. O processo requer intervenção cirúrgica, e qualquer infecção localizada pode facilmente alastrar-se. Além disso, qualquer perda de contato entre os eletrodos e as raízes neurais pode causar, no melhor dos casos, movimentos indesejáveis, e possivelmente lesões na estrutura neural adjacente.

1.4.4 Por Que Usar a EENM?

A EENM não tem como vantagem somente a restauração parcial da locomoção. Há uma série de outros benefícios. Com a EENM, a atrofia muscular pode ser reduzida (Fournier *et al.*, 1984), além dos efeitos cardiovasculares decorrentes da contração muscular ativa. Durante a marcha com órteses, a EENM não só permite uma melhor movimentação dos membros afetados, mas também requer um esforço menor nas partes não afetadas (Cliquet, 1988).

Outros benefícios foram citados acima (seção 1.2.2) com respeito às vantagens decorrentes da restauração da locomoção em pacientes medulares.

1.5 SISTEMAS HÍBRIDOS

No início dos trabalhos com EENM, pensava-se que o progresso viria de forma rápida. Acreditava-se que somente a EENM, sem a ajuda de sistemas mecânicos, traria bons resultados. Este não foi o caso, e a solução encontrada foi uma combinação de estimulação elétrica e órteses de tipos discutidos acima. Ao usar estes sistemas híbridos, propostos originalmente por Tomovic *et al.* (1972), fica mais fácil controlar a EENM, já que o número de graus de liberdade e a carga mecânica são reduzidos. Sistemas híbridos também reduzem o gasto energético do paciente em comparação ao uso exclusivo de órteses (Nene, 1989; Solomonow *et al.*, 1989).

O grau de redução na complexidade do movimento é uma consequência do tipo de órtese usada. Órteses do tipo AFO ('ankle-foot'), restringem os movimentos no tornozelo (em geral, completamente). KAFOs restringem os movimentos do joelho e do tornozelo. Apesar de que os movimentos nestas juntas são eliminados por completo na maioria dos casos, há sistemas que permitem um pouco de rotação no joelho mediante o uso de dispositivos de atrito controlados eletricamente (Schoenberg e Long, 1987). Além das restrições no joelho e no quadril, HGOs também limitam o movimento do quadril ao plano sagital. RGOs reduzem ainda mais os graus de liberdade ao acoplar um quadril ao outro, e ao limitar os movimentos do tronco (Douglas *et al.*, 1983).

Sistemas híbridos, na sua maioria, não têm elementos mecânicos ativos. Isto significa que eles simplesmente limitam os movimentos, reduzindo o comprimento de cada passo e aumentando a necessidade de balanço do tronco para a liberação do pé. Porém, sistemas como o desenvolvido por Schoenberg e Long reduzem a carga muscular sem necessariamente eliminar graus de liberdade. Mecanismos ativos também reduzem a demanda computacional relacionada ao controle da EENM mediante a possível eliminação da estimulação em fases de contrações excêntricas (Durfee e Hausdorff, 1990).

Na década de 1980, Popovic (1990) apresentou a órtese **SFMO** ('self-fitting modular orthoses'). Este sistema combina EENM com uma órtese ativada por motores. Ele limita os movimentos nas juntas ao plano sagital ao mesmo tempo em que a órtese se alinha com a junta durante o movimento (daí o nome 'self-fitting', ou auto-ajustável). A SFMO também inclui controle por um sistema especialista que possibilita a execução de vários movimentos (andar num plano e numa rampa, sentar, ficar em pé, caminhar para trás, rotação ao redor de um eixo vertical). Porém, este sistema aproxima-se mais de uma robotização do paciente do que de uma verdadeira reabilitação dos movimentos usando as habilidades que ainda restam ao paciente.

Outros sistemas híbridos de relevância têm sido propostos por McClelland *et al.* (1987), Petrofsky *et al.* (1984), Popovic *et al.* (1989), Jaeger (1986), Ewins *et al.* (1988), Andrews (1990), Andrews *et al.* (1988), Andrews e Bajd (1984), Hausdorff e Durfee (1988), e Cliquet *et al.* (1986) entre outros.

Um fator positivo adicional resulta do uso de órteses como complemento à EENM pura: a redução de lesões mediante a limitação dos movimentos. Este fator é muito importante para pacientes medulares já que frequentemente eles não tem sensações que acusem uma lesão nos membros afetados. Além disto, é mais fácil acoplar sensores biomecânicos a uma órtese que acoplá-los ao corpo humano, facilitando a confecção de sistemas de malha fechada. E, no pior dos casos, se falhar a EENM, a órtese serve como apoio e como meio de locomoção.

Por estas razões, sistemas híbridos são os preferidos hoje para a reabilitação da marcha em pacientes medulares. No sistema apresentado nesta tese, entretanto, teve-se em mente a produção da marcha por EENM pura, apesar de que o algoritmo de controle pode ser facilmente adaptado a um sistema híbrido.

1.6 OBJETIVOS

O objetivo desta tese foi explorar o uso de redes neurais artificiais para o controle da marcha produzida via EENM em pacientes medulares. Para tanto, dois sistemas foram testados. O primeiro, mais simples, é um sistema experimental com dois canais de estimulação para a produção da fase de balanço. Este sistema, em suas várias versões, foi submetido a testes com pacientes. O segundo, mais complexo, é um sistema hipotético de cinco canais para produção do ciclo completo da marcha. Este segundo sistema foi testado em simulações no computador e permitiu testes com diversas arquiteturas neurais.

Apesar de que ambos sistemas podem ser usados com órteses e eletrodos de vários tipos, os testes foram feitos tendo em mente a produção da marcha recíproca somente com eletrodos de superfície e com a ajuda de muletas.

De qualquer forma, durante o desenvolvimento deste trabalho teve-se como prioridade usar sistemas computacionais simples (dentro do possível). Desta forma, e somente desta forma, o trabalho poderá ser adotado por profissionais tanto da área tecnológica como da área médica.

CAPÍTULO 2

REDES NEURAIIS ARTIFICIAIS

E O CONTROLE DA MARCHA

O

controle inteligente foi inicialmente proposto por Fu (1971) para aumentar a flexibilidade e a faixa funcional de sistemas de controle automático existentes na época. Sistemas de controle inteligente não são definidos de acordo com um algoritmo específico. Por outro lado, eles têm como característica comum a habilidade de ‘sentir’ e ‘estudar’ o meio ambiente e, como resultado, a capacidade de executar funções de forma flexível e robusta (Antsaklis e Passino, 1992). Tendo estes fatores como meta, pesquisadores têm se dedicado ao estudo de arquiteturas de sistema apropriadas, processamento sensorial, controle com aprendizado, e modelamento matemático (Albus, 1991). Neste contexto, será discutida a aplicação de redes neurais artificiais no controle inteligente e modelamento da locomoção (para uma abordagem geral do uso de redes neurais em sistemas de controle, veja Brown e Harris, 1994, Harris, 1994, e Miller *et al.*, 1990).

Considerando que esta tese representa o primeiro esforço registrado a nível mundial para controlar a marcha em pacientes medulares por meio de redes neurais artificiais, a pergunta que o(a) leitor(a) deve ter em mente ao ler este capítulo é a seguinte: Qual é a vantagem em usar redes neurais em comparação a outros sistemas?

2.1 INTRODUÇÃO A REDES NEURAIS

Apesar da identificação dos neurônios por Cajal ter acontecido cem anos atrás, o modelamento matemático de redes neurais só teve início cinquenta anos mais tarde. Tentativas de modelamento tiveram que esperar até que a complexidade na estrutura e função dos neurônios fosse ao menos parcialmente desvendada pelo próprio Cajal e seus contemporâneos Golgi e Sherrington (Cowan e Sharp, 1988; Santini, 1975). Mais tarde, os modelos foram enriquecidos por trabalhos desenvolvidos por Sholl (1956) e por alguns dos pilares da neurobiologia como Eccles (1957) e Hodgkin e Huxley (1952), entre outros.

O trabalho que deu origem ao modelamento de redes neurais esteve diretamente associado a estudos neurobiológicos (McCulloch e Pitts, 1943). O modelo neuronal de McCulloch e Pitts é mostrado, com modificações, nas Figuras 1 e 2. Na Figura 1, a resposta do neurônio é determinada por uma função de ativação sigmoideal (no modelo de 1943, a função de ativação era binária, mas a sigmoideal é mostrada aqui por ser a usada neste trabalho). O peso sináptico representa o grau de excitabilidade ou inibição que um determinado estímulo causa no soma neuronal. Nos modelos de redes neurais, os pesos sinápticos podem frequentemente mudar de sinal, o que não acontece em sistemas biológicos (para uma discussão de algumas diferenças entre modelos neurais e fatos biológicos, veja McClelland *et al.*, 1986). O neurônio na Figura 2 tem uma camada **C1** que contém o vetor do sinal de entrada a_i . S_i representa a transformação sofrida (se alguma) pelo vetor antes que ele atinja o corpo neuronal em **C2** e constitui o estímulo recebido pelo neurônio. O nível de atividade do soma em **C2** é determinado pela função de McCulloch e Pitts:

$$x_j = \sum_i s_i w_{ij}$$

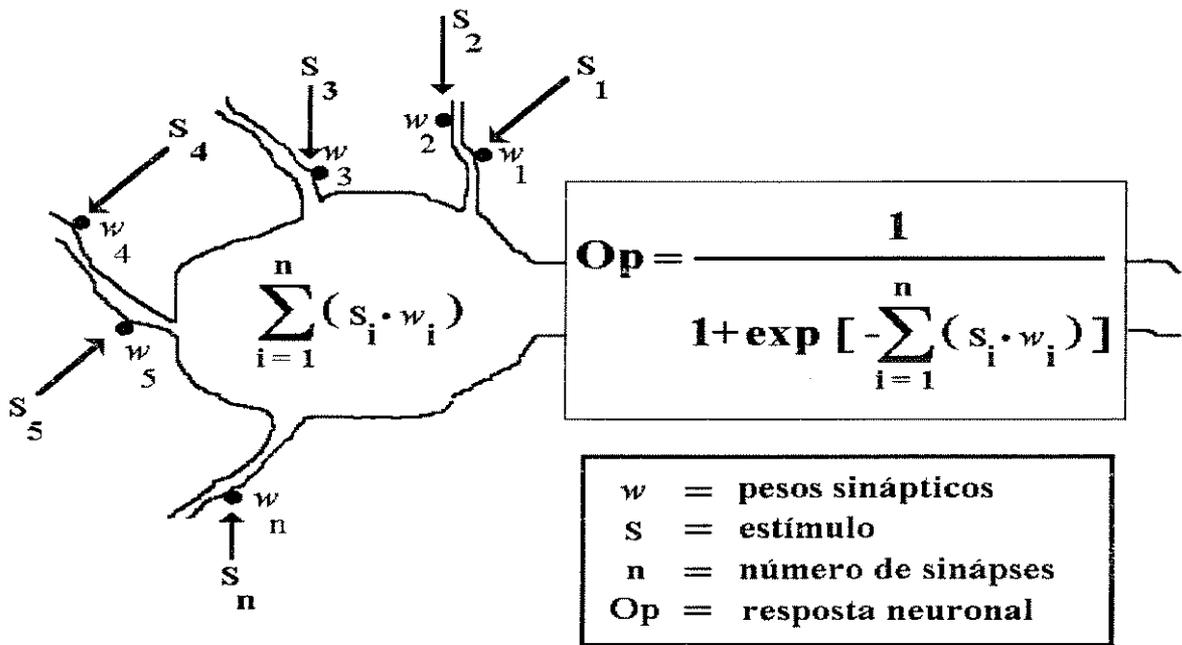


Figura 1 - Modelo de processamento neuronal simplificado. Sinais de estímulo podem inibir ou excitar o soma, dependendo do sinal do peso sináptico. A resposta do neurônio é dada pela função de ativação, tradicionalmente definida como uma sigmóide.

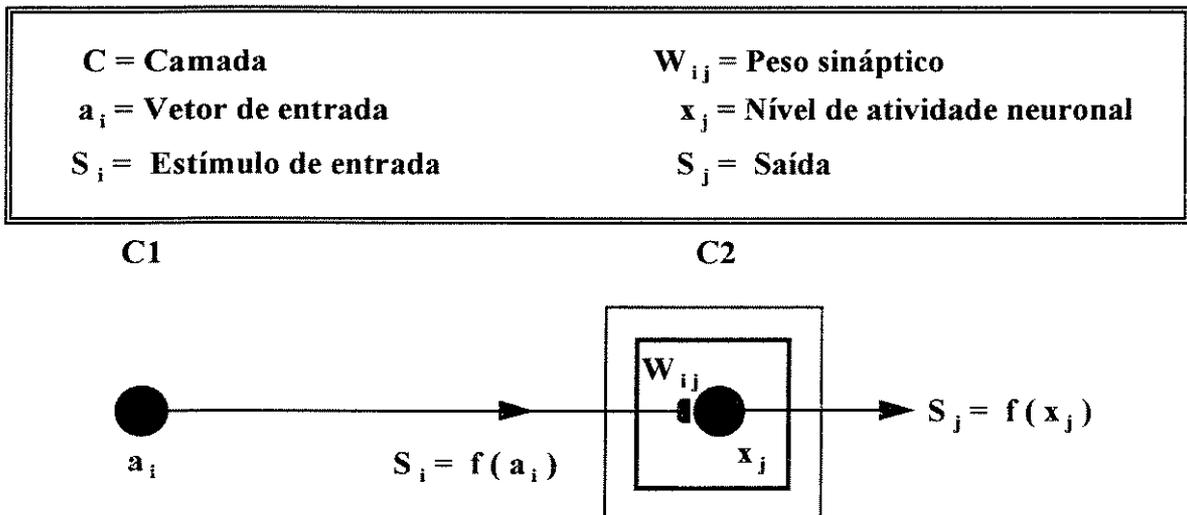


Figura 2 - Neurônio de McCulloch e Pitts (com modificações). Todos os elementos têm seu equivalente na Figura 1 acima. No caso mais simples, $S_j = x_j$ e $S_i = a_i$. Com frequência, no entanto, S_j é sigmoidal como Op (Figura 1).

Elementos como os mostrados na Figura 2 foram usados com sinais de saída binários. Isto permitiu a simulação de funções lógicas. Através deste estudo, McCulloch e Pitts provaram que redes neurais artificiais, dotadas de memória suficiente, podem ser consideradas máquinas computacionais universais de acordo com os critérios definidos por Alan Turing (para uma análise informal dos critérios de Turing veja Penrose, 1989). Entretanto, o trabalho de McCulloch e Pitts tinha inicialmente pesos sinápticos constantes. Isto significa que o modelo não era adaptativo, o que neste caso corresponde a dizer que o modelo não era capaz de aprender.

A geração seguinte de modelos neurais levava em conta adaptações sinápticas. Dentre os modelos que surgiram nos anos cinquenta e sessenta, o **Perceptron** de Frank Rosenblatt tem o maior significado histórico e prático (Rosenblatt, 1958, 1962). O Perceptron é basicamente um neurônio de McCulloch e Pitts com capacidade de aprendizado (Figura 3). A Figura 3b contém um modelo cuja importância dura até hoje, o Perceptron com retro-acoplamento. Neste modelo, os pesos sinápticos são modificados de acordo com a diferença entre a saída neuronal e uma saída desejada. Originalmente usou-se uma relação estatística entre as duas saídas. Curiosamente, muitos confundem este retro-acoplamento ('back-coupling') do erro com o algoritmo de retro-propagação ('back-propagation'), a ser discutido mais abaixo. No entanto, este último deriva seu nome da propagação dos pesos sinápticos e suas derivadas de uma camada para outra (Carpenter, 1989); a propagação do erro é mera consequência.

Após o Perceptron, surgiram trabalhos que calculavam a diferença vetorial entre as saídas neuronal e desejada. O Adaline ('adaptive linear neuron', ou neurônio adaptativo linear), por exemplo, incluiu mais de uma camada de neurônios (Widrow e Smith, 1963). Tanto o Adaline como o Perceptron tinham uma regra de adaptação sináptica do tipo

$$\frac{dW_{ij}}{dt} = c\delta_i \frac{a_j}{|a_j|^2}, \text{ onde } c \text{ é uma constante e } \delta_i \text{ é a diferença entre as saídas neuronal e desejada.}$$

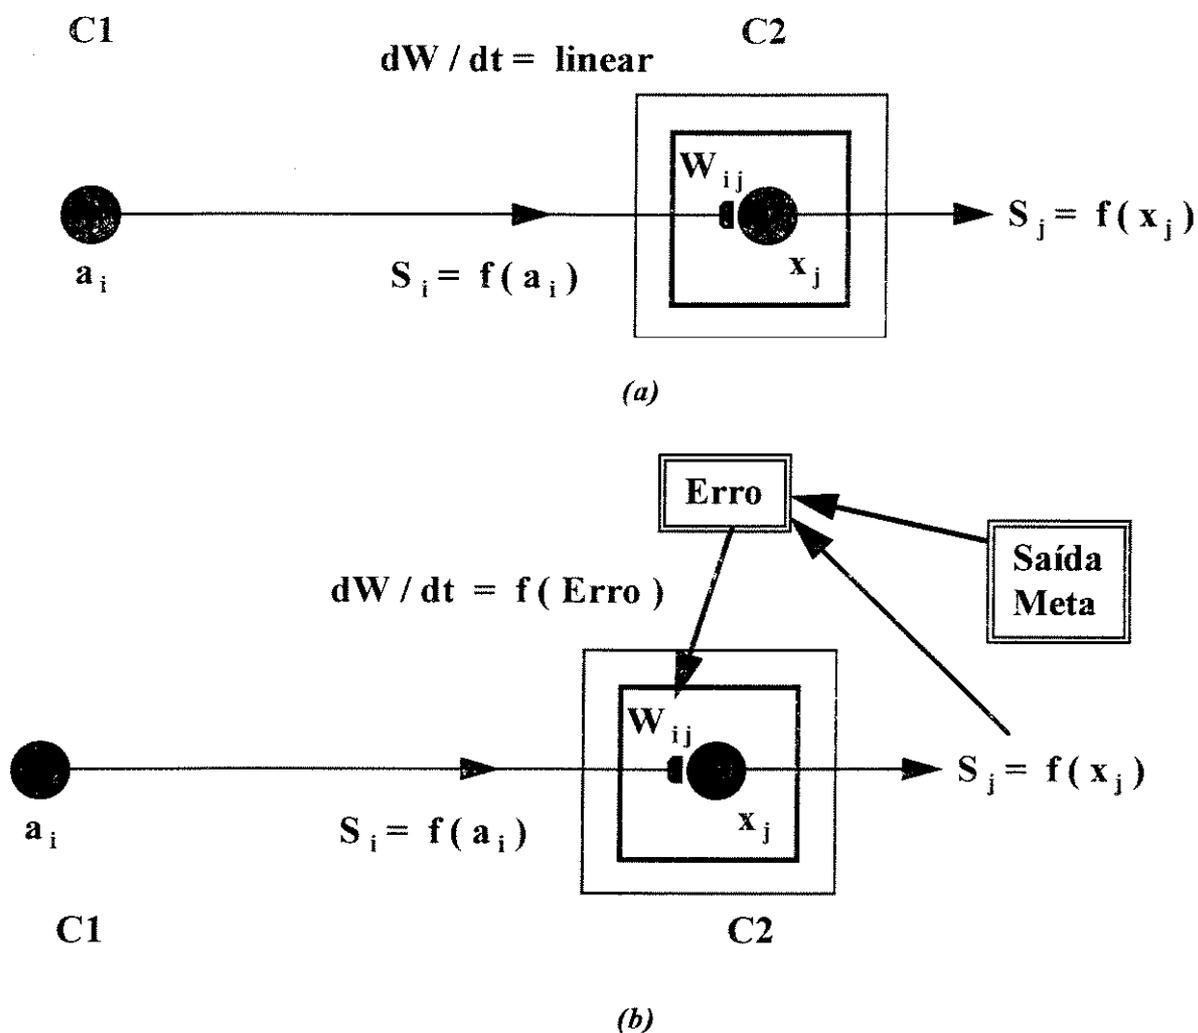


Figura 3 - O Perceptron de Rosenblatt. Em (a), os pesos sinápticos mudam linearmente com respeito ao tempo. Em (b), a adaptação sináptica é uma função da diferença entre a saída neuronal e uma saída desejada.

O Adaline e o Perceptron tinham também outro fator em comum; ambos tinham sérias limitações relacionadas basicamente ao uso de funções de ativação lineares e de passo. Este problema foi explorado por Minsky e Papert no livro 'Perceptrons' (Minsky e Papert, 1969). Muitas das falhas apontadas neste livro já haviam sido discutidas por Rosenblatt num dos capítulos de seu livro 'Principles of Neurodynamics' (capítulo intitulado 'Summary of three layer series-coupled systems: Capabilities and deficiencies'). Mas isto não impediu que as instituições de apoio à pesquisa nos Estados Unidos perdessem o interesse em redes neurais

artificiais. Como consequência, até os anos oitenta, pouco foi feito nesta área naquele país (e muitos trabalhos, mas de pequeno significado, foram desenvolvidos na Europa, trabalhos estes reunidos em Aleksander, 1989). Em 1982, Hopfield propôs um mecanismo que relacionava a eficiência do aprendizado com minimização da energia em redes de várias camadas. Hopfield fez uso de idéias desenvolvidas por Grossberg dez anos antes. Estas consistiam de equações que representavam o comportamento de associação em redes neurais biológicas (Grossberg, 1988a). A rede neural desenvolvida por Hopfield era uma rede de várias camadas, com saídas binárias e pesos sinápticos predeterminados (variava o estado dos neurônios, entre ligados e desligados). As aplicações deste tipo de rede são poucas, mas o trabalho foi importante por que trouxe uma descrição matemática dos processos dinâmicos envolvidos no aprendizado em redes neurais.

Pouco tempo depois reapareceu aquele que ainda é o mais popular dos algoritmos de aprendizado supervisionado, a **Retro-Propagação** ('Back-Propagation'). Este algoritmo foi concebido originalmente por Werbos (1974) e mais tarde foi redescoberto independentemente por Parker (1982) e Le Cun (1985). A versão mais popular da retro-propagação é a produzida por Rumelhart e colaboradores (1986a, 1986b). Geralmente, a retro-propagação inclui neurônios de McCulloch e Pitts com uma função de ativação sigmoideal (Figuras 1 e 2) e com retro-acoplamento do erro (Figura 3). Após passar pelo primeiro grupo de pesos sinápticos W_{ij} , um vetor de entrada converge na camada C2 (Figura 4), agora 'escondida', ou entre duas outras camadas de processamento. Então, o sinal S_j viaja até C3, gerando a resposta total da rede, S_k . Esta resposta é depois comparada ao vetor de saídas desejadas, b_k , e a diferença entre os dois é retro-acoplada aos pesos W_{jk} . Para garantir convergência dos pesos sinápticos, o erro é multiplicado pela derivada $f'(x_k)$. Os novos pesos sinápticos W_{jk} são então incorporados ao termo de erro associado à camada C2, δ_j . Este último processo constitui a retro-propagação.

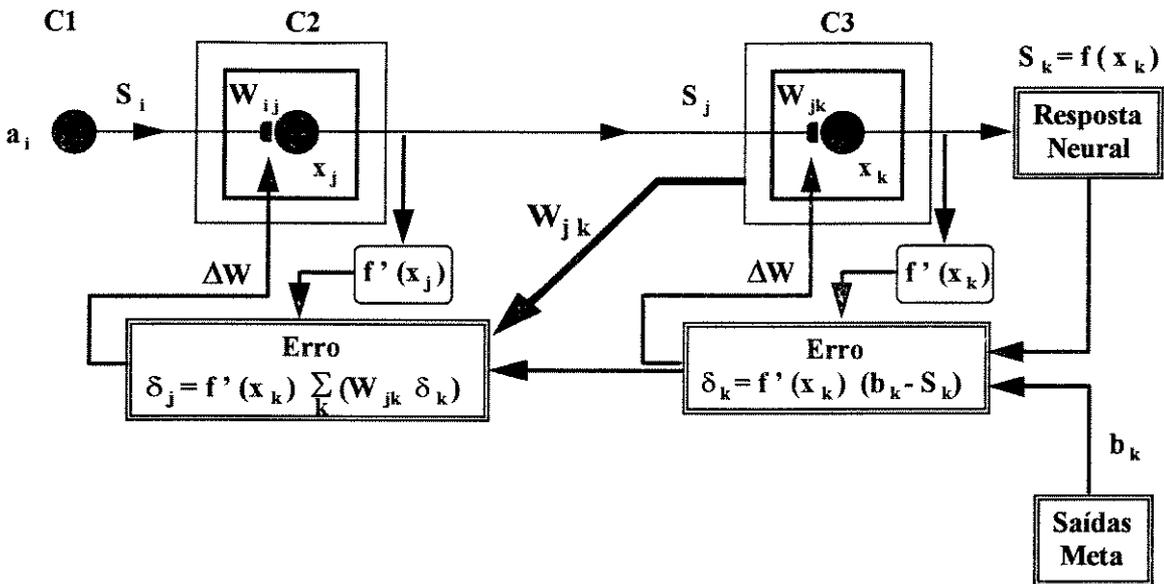


Figura 4 - Esquema do algoritmo de retro-propagação. Há três camadas de processamento (C1, C2, e C3), apesar de que normalmente S_i é definido igual a a_i . O erro é retro-acoplado de C3 a C2. Já W_{jk} (devidamente corrigido) é retro-propagado de C2 para C3 (veja a flecha mais grossa).

Na Figura 5 pode-se ver como funciona a retro-propagação numa rede de vários elementos em cada camada (um diagrama em blocos com as equações usadas no algoritmo pode ser visto no Apêndice A). Esta é a estrutura básica das redes neurais usadas neste trabalho. Mais será dito sobre este algoritmo na seção 2.2.2.

2.2 CONTROLE POR REDES NEURAIS

2.2.1 Estratégias de Modelamento e Controle

Há quatro tipos básicos de arquitetura para controle com redes neurais. Estas arquiteturas são independentes do tipo de rede neural e algoritmo de aprendizado. Elas são: modelo da planta, modelo inverso da planta, modelo especializado inverso da planta, e modelo do operador (Figura 6) (Hunt *et al.*, 1992, Widrow e Stearns, 1985). Em três destas arquiteturas (Figuras 6a, 6b, e 6d), a saída meta da rede neural é conhecida e, portanto,

qualquer regra de aprendizado supervisionado pode ser usada (veja abaixo, seção 2.2.4). No esquema da Figura 6c, o erro é formado na saída da planta, sendo que a resposta da rede constitui a entrada da planta. Neste caso, é necessário encontrar alguma forma para usar o erro na saída numa retroalimentação para se obter o modelo inverso da planta.

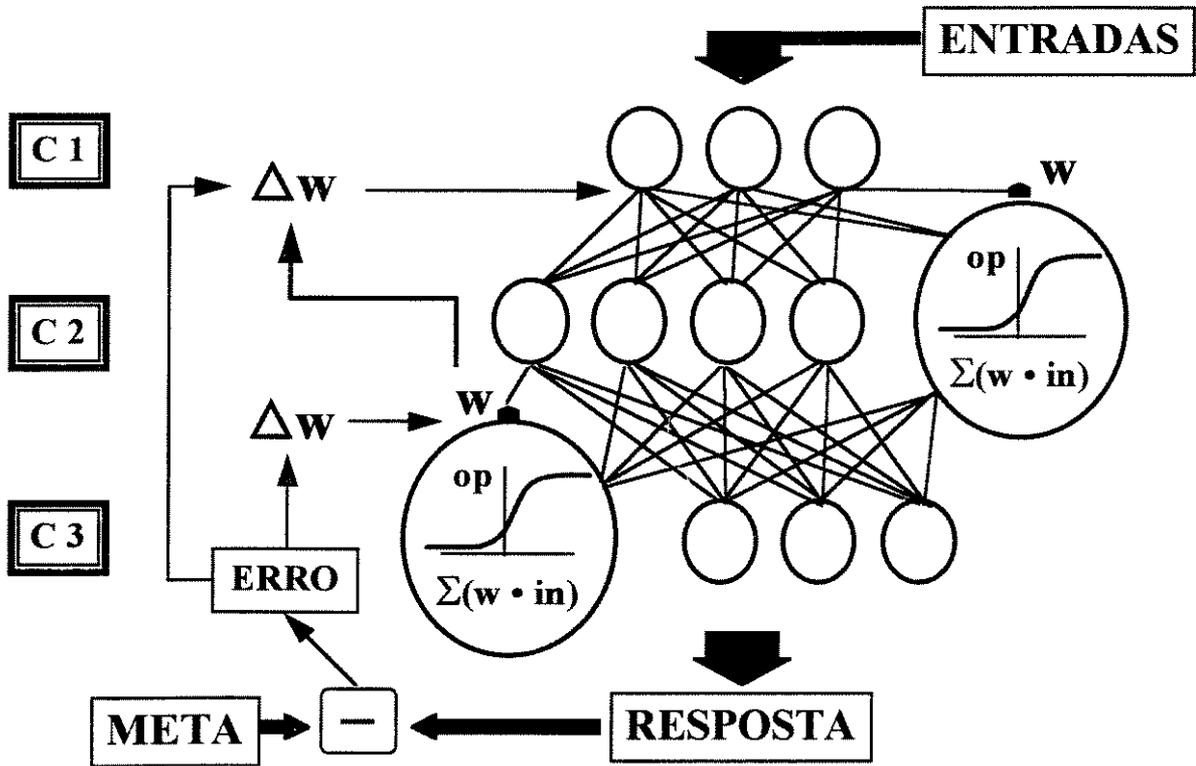


Figura 5 - Diagrama de processamento em uma rede neural de três camadas, com vários elementos por camada, e função de ativação sigmoideal. As entradas nos neurônios de C1 são passadas diretamente para a camada escondida (C2) onde é aplicada a função sigmoideal (Op) em cada neurônio. As saídas de C2 viajam até C3, onde Op é novamente calculado para cada neurônio. Este processo é conhecido como 'feedforward', ou avanço. O vetor de resposta total da rede é então comparado ao vetor de saídas meta, ou desejadas, e os novos pesos sinápticos são calculados como mostrado na Figura 4 (cada conexão entre um neurônio e outro é um peso sináptico único), o que constitui o processo de 'feedback', ou retroalimentação. Durante o aprendizado (iniciado com pesos sinápticos aleatórios), para cada grupo de entradas é feito o avanço e a retroalimentação, até que o erro seja menor que um valor de tolerância pré-estipulado. Uma vez treinada a rede neural, somente o avanço é feito.

O sucesso de cada um dos esquemas na Figura 6 depende da distribuição dos dados de entrada (idealmente, esta distribuição deve ser representativa de todo o espaço de entrada), da capacidade de aproximação e generalização da rede neural, e da habilidade do algoritmo de treinamento de reduzir o ruído inerente no modelamento e medições. Este último fator é frequentemente o mais difícil de ser conseguido e avaliado.

No **modelamento da planta**, o sinal de controle e o estado da planta são usados como o vetor de entrada para a rede neural (nesta abordagem, por 'modelo' entenda-se rede neural, mas há outras estratégias para o modelamento). A saída meta é a resposta da planta.

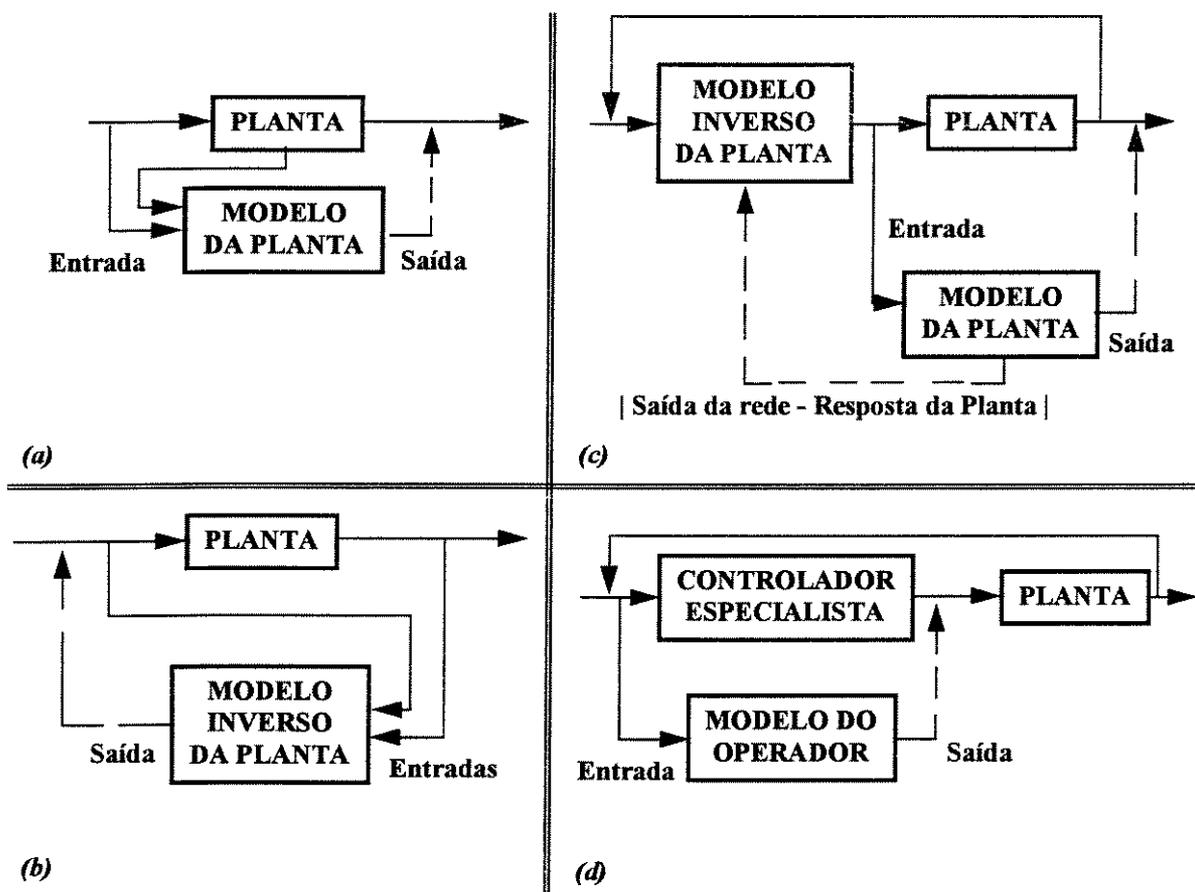


Figura 6 - Modelamento do aprendizado do controle. (a) modelo da planta, (b) modelo inverso da planta, (c) modelo especialista inverso da planta, e (d) modelamento do operador. Entradas e saídas meta referem-se à rede neural (veja Figura 5).

Ao ser feito um **modelo inverso da planta** (Figura 6b), deseja-se obter um controlador de forma que a função de transferência do esquema de controle tenha valor unitário. Inevitavelmente, erros no modelamento afastam o sistema deste valor unitário. Mas esta arquitetura, como complemento a um controlador linear, traz bons resultados quando aplicada em sistemas não lineares (Brown e Harris, 1994). Neste esquema, a rede é treinada tendo como entradas o sinal de controle e a resposta da planta, e como saída o sinal de controle.

No sistema com **modelamento especializado invertido da planta** (Figura 6c), também se quer obter uma função de transferência unitária. Primeiro é construído um modelo direto da planta. Então, é calculado o erro (neste caso, a diferença entre a resposta da planta e a resposta desejada), que é posteriormente repassado pelo modelo direto da planta, permitindo ajustes no modelo inverso. Neste esquema, somente o modelo direto da planta é submetido a aprendizado formal.

A técnica de **modelamento do operador especialista** tem inúmeras aplicações no controle inteligente (Shepanski e Macy, 1987, Widrow, 1987). O algoritmo de aprendizado é rodado ao mesmo tempo que um operador especialista executa o controle do sistema. Tanto o operador como a rede neural recebem como entrada a resposta da planta. A saída meta da rede neural passa a ser o grupo de decisões tomadas pelo controlador (seja ele humano ou não). No caso de o controlador especialista ser um humano, os dados para treinamento podem ter um alto nível de ruído (resultado da frequente subjetividade das decisões do operador). Isto pode exigir que sejam filtrados os vetores de entrada e saídas meta antes de treinar a rede. Esta arquitetura é ideal para casos em que pouco se sabe sobre a planta ou quando a planta é variável no tempo, impossibilitando o modelamento da planta, seja ele inverso ou direto.

2.2.2 Algoritmos para Treinamento das Redes

O fator que levou ao popular e recente uso de redes neurais em esquemas de controle é a habilidade que as redes têm de aprender a fazer mapeamentos extremamente complexos. Para poder fazer este mapeamento, redes neurais podem ser treinadas de forma **supervisionada**, **não supervisionada**, e **por reforço** (há outras maneiras além destas, mas esta discussão limita-se a estas três).

2.2.2.1 Treinamento Não Supervisionado

No treinamento **não supervisionado**, a adaptação sináptica ocorre em malha aberta. Para tanto, várias estratégias têm sido usadas, a saber (Brown e Harris, 1994):

- **agrupamento** dos dados de entrada em aglomerações que podem ser rotuladas de forma supervisionada,
- **otimização** do espaço de dados de entrada,
- **representação** do espaço de entrada em um espaço de menos dimensões, e
- **extração** de padrões dos dados de entrada.

Normalmente as estratégias de aprendizado não supervisionado estão intimamente ligadas à estrutura da rede neural (Grossberg, 1988b). Elas têm sido usadas em aplicações variadas, como compressão de imagens (Nasrabadi e Feng, 1988), modelamento de robôs (Ritter *et al.*, 1989), e reconhecimento da fala (Kohonen, 1988). Os três esquemas mais conhecidos são o **aprendizado competitivo**, o **mapa auto-organizado**, e a **teoria de ressonância adaptativa**.

Redes neurais **competitivas** tem nódulos (equivalentes aos neurônios) distribuídos em paralelo ao espaço de dados de entrada. Estes nódulos constituem uma representação

estatística dos dados apresentados à rede neural. Os pesos sinápticos neste caso são vetores conectando o espaço dos dados de entrada com o espaço dos nódulos. A etapa de avanço (definida na Figura 5 acima) numa rede deste tipo consiste em achar o nódulo que melhor representa um determinado vetor de entrada. O vetor de pesos associado a este nódulo é então modificado (Lippmann, 1987). Estas redes podem ser usadas como sistemas de classificação se rótulos são associados aos nódulos.

Mapas auto-organizados (Kohonen, 1990) são redes competitivas com distribuição organizada dos nódulos. Estes mapas têm como meta gerar uma representação do espaço de entrada (n dimensões) com poucas dimensões (m dimensões, sendo que $m < n$), ao mesmo tempo que é conservada a topologia do espaço. A organização é feita de tal maneira que se dois dados de entradas estão próximos, os dois nódulos associados devem também ficar próximos (no espaço de m dimensões).

A **teoria de ressonância adaptativa** (ART, sigla em inglês) vem sendo desenvolvida por Grossberg e seu grupo na Universidade de Boston desde os anos sessenta. A principal meta deste grupo é criar sistemas que possam adaptar-se sensivelmente a eventos novos significativos, ao mesmo tempo em que o sistema mantém-se estável em resposta a eventos não importantes (Carpenter and Grossberg, 1988). Este é o chamado dilema da 'estabilidade-plasticidade', um dos principais focos de estudo em controle inteligente 'on-line'. A ART lida com este problema e tem ainda as seguintes características: normalização do espaço de entrada, alto contraste entre vetores de entrada, e distinção entre memória a longo prazo e memória a curto prazo. Redes baseadas em ART podem lidar com vários tipos de dados de entrada, como sinais binários (Grossberg, 1988a), sinais de valor real (Carpenter *et al.*, 1991), e estruturas hierárquicas (Carpenter e Grossberg, 1990). Uma discussão do funcionamento deste tipo de redes vai além do escopo desta tese, mas ART merece menção aqui por ser de extrema importância no modelamento e controle por redes neurais.

2.2.2.2 *Treinamento Supervisionado*

No treinamento supervisionado, existe uma saída meta $\hat{y}(t)$ associada a cada vetor de entrada $\mathbf{a}(t)$. A diferença entre a resposta da rede e a saída meta é dada por

$$e_y(t) = \hat{y}(t) - y(t),$$

onde $e_y(t)$ é o erro, e $y(t)$ é a resposta da rede.

Nos algoritmos supervisionados, o erro é minimizado. No entanto, somente esta minimização do erro não garante que uma rede treinada 'off-line' tenha um comportamento adequado quando usada em modo de avanço. O treinamento é feito com uma base de dados limitada, reduzindo a capacidade de generalização da rede. Para melhorar a capacidade de generalização, os algoritmos supervisionados frequentemente usam técnicas de otimização dos parâmetros (como pesos sinápticos) da rede. A questão da convergência em direção a um estado ótimo é, então, crucial. Dentre as técnicas usadas para este fim, regras de descendência por gradiente (a retro-propagação é uma delas) são as mais populares. Esta popularidade deve-se a fatores históricos (O algoritmo original de Widrow e Smith, 1963, era deste tipo), como também ao fato de que o algoritmo tem pouca necessidade de memória e custo computacional relativamente baixo.

Dentro da família de algoritmos supervisionados, há dois tipos diferentes: regras instantâneas e regras do tipo 'batch', ou por lote. Na técnica **instantânea**, para cada par entrada-saída meta, $\{\mathbf{a}(t), \hat{y}(t)\}_t$, é feita a modificação dos pesos sinápticos. Já na técnica **por lote**, faz-se a atualização dos pesos depois de apresentar à rede o conjunto completo dos pares entrada-saída (o erro é acumulado), $\{\mathbf{a}(t), \hat{y}(t)\}_{t=1}^L$.

Para o treinamento das redes, é definida uma função de custo J que permite avaliar o desempenho do processo. Frequentemente, a função usada é a da média do quadrado do erro (MQE) dada por (para treinamento por lote)

$$J = E(\epsilon_y^2(t)) = \frac{1}{L} \sum_{t=1}^L \epsilon_y^2(t).$$

Nos algoritmos de descendência por gradiente, a adaptação dos pesos ΔW é feita no sentido negativo da gradiente da função de desempenho, ou seja

$$\Delta W = -\frac{\mathfrak{R}}{2} \frac{\partial J}{\partial W} = \mathfrak{R} E\left(\frac{\partial y(t)}{\partial W} \epsilon_y(t)\right),$$

onde \mathfrak{R} é a taxa de aprendizado. Nesta equação vê-se que a modificação sináptica é uma função tanto do erro $\epsilon_y(t)$ como da estrutura da rede (contida no Jacobiano $\frac{\partial y(t)}{\partial W}$). Caso a relação entre a resposta da rede e os pesos seja linear ($y(t) = x^T(t)W$), onde $x(t)$ é o estado de ativação de um neurônio (seção 2.1 acima), a expressão acima reduz-se a

$$\Delta W = \mathfrak{R} E(\epsilon_y(t)x(t)).$$

No treinamento instantâneo, a correção dos pesos sinápticos é feita após a apresentação de cada par entrada-saída. Isto permite seu uso em esquemas de treinamento tanto 'on-line' como 'off-line'. A função de custo neste caso é $J(t) = \epsilon_y^2(t)$. Usando a regra da descendência por gradiente,

$$\Delta W = -\frac{\mathfrak{R}}{2} \frac{\partial J}{\partial W} = \mathfrak{R} \frac{\partial y(t)}{\partial W} \epsilon_y(t).$$

No caso de uma rede linear,

$$\Delta W = \mathfrak{R} \epsilon_y^2 x(t).$$

Um problema sério com regras de descendência por gradiente (instantâneas ou por lote) é o fato de que elas podem ficar presas em mínimos locais (Figura 7). Isto pode ser resultado de taxas de aprendizado muito baixas ou de modelamento impróprio (e.g., estrutura de conectividade não favorável para a lista de dados de treinamento). Por outro lado, taxas de aprendizado fazem com que o estado da rede varie drasticamente, talvez nunca chegando a um mínimo desejado.

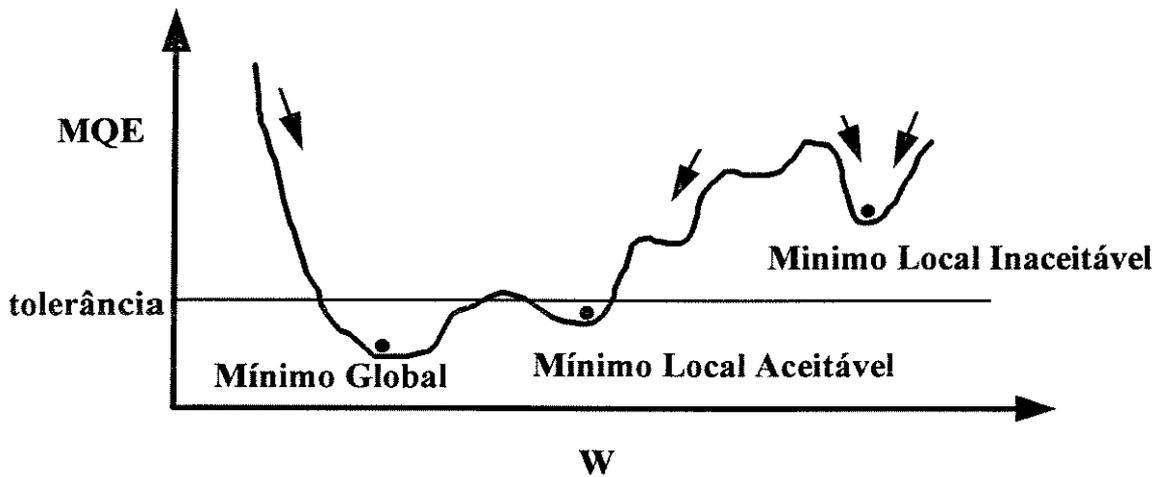


Figura 7 - Variação do MQE com respeito ao estado da rede (pesos sinápticos W). As flechas indicam a convergência em direção a um estado ótimo. O processo de aprendizado é interrompido quando o MQE atinge um valor abaixo de uma tolerância predeterminada (A figura é mera ilustração; o espaço de pesos sinápticos tem n dimensões, sendo que n pode passar dos milhares).

Para evitar que a rede entre em mínimos locais inaceitáveis, é necessário perturbar os pesos sinápticos e a taxa de aprendizado durante o aprendizado. A velocidade com que um mínimo aceitável é atingido depende da taxa de aprendizado, do nível de tolerância, e especialmente do estado inicial dos pesos (geralmente atribuídos valores aleatórios ao iniciar-se o processo de aprendizado).

Outros esquemas supervisionados de sucesso são os algoritmos estocásticos e genéticos. Algoritmos estocásticos usam elementos aleatórios na busca da matriz de pesos ideal. Eles podem ser usados quando a resposta da rede não é uma função continuamente diferenciável com respeito aos pesos. Neste caso, é feita uma procura aleatória pelo estado de pesos que gere uma função de custo com valor reduzido. A procura aleatória pode também complementar um algoritmo de descendência por gradiente. De qualquer forma,

esquemas de descendência por gradiente geralmente têm um desempenho muito mais rápido que os algoritmos estocásticos (Monzingo e Miller, 1980).

Algoritmos **genéticos** foram introduzidos por Holland em 1975. Entretanto, seu uso tem se tornado popular somente nos últimos cinco anos. Neste algoritmo, os pesos sinápticos são representados por cadeias binárias. Estas cadeias menores são concatenadas para formar um cordão. Vários cordões são então combinados através de técnicas genéticas como cruzamento e mutação aleatória. Os cordões novos que resultarem num melhor desempenho da rede neural têm maior probabilidade de sobrevivência, sendo preservados para novas combinações. Apesar de o uso de esquemas genéticos ser recente, eles têm sido usados com sucesso em várias aplicações, especialmente aquelas que envolvem cálculos de otimização complexos (McGregor *et al.*, 1992; Renders e Hanus, 1992).

2.2.2.3 *Treinamento por Reforço*

Nos esquemas de treinamento por reforço, o algoritmo de aprendizado inclui elementos referentes ao desempenho do sistema no controle. Estas variáveis de desempenho são normalmente binárias, indicando se houve ou não sucesso na tarefa. O principal trabalho nesta área consistiu em usar um esquema de reforço para controlar um pêndulo invertido (Barto *et al.*, 1983). As redes neurais usadas em sistemas deste tipo são normalmente similares a tabelas de referência, ainda que outras arquiteturas neurais têm sido usadas (Anderson, 1989; Zhang e Grant, 1992). Outros pesquisadores têm usado esquemas de reforço no controle de um pêndulo invertido, confirmando a eficácia de sistemas com treinamento por reforço em problemas deste tipo (Berenji e Khedkar, 1992).

O esquema de reforço concebido para esta tese é diferente dos trabalhos aqui citados (veja Capítulo 4). A idéia de utilizar variáveis indicativas do desempenho do controlador, entretanto, é levada em conta neste trabalho.

2.3 MODELAMENTO E CONTROLE DE MOVIMENTOS

POR REDES NEURAIAS

Algoritmos do tipo retro-propagação e outros têm sido usados no modelamento e controle de movimentos em vários sistemas. Questões como controle hierárquico (Kawato *et al.*, 1987), movimentos dirigidos a uma meta (Coiton *et al.*, 1991; Dean 1990), e geradores centrais de padrões (Kalveram, 1991) têm sido abordadas em relação a movimentos de braços e pernas em humanos, robôs, e mesmo em insetos. Nenhum destes trabalhos têm simplicidade computacional suficiente para ser usados neste trabalho, mas alguns mais relevantes merecem menção aqui por abordarem questões úteis para trabalhos futuros.

Beuter *et al.* (1986) modelaram movimentos da marcha usando um modelo de três elementos e quatro graus de liberdade. Os movimentos foram simulados usando como meta as trajetórias dos três elementos. Num estudo relacionado a este, Flashner *et al.* (1987) adicionaram mais um elemento ao modelo. Este último trabalho gerou um sistema baseado em controle hierárquico que permitiu a combinação de estratégias de controle tanto em malha aberta como em malha fechada. Outro estudo a usar controle hierárquico foi Wang *et al.* (1992). Este último consistiu no uso de uma rede neural no controle de um robô bípede. O trabalho concluiu que o controlador neural é superior a outros algoritmos quando os distúrbios são grandes.

Amirikian e Lukashin (1992) desenvolveram uma rede neural para controle motor levando em conta características gerais do movimento (usando o princípio da ação mínima de Hamilton), em contrapartida ao uso generalizado de sequências de estado específicas. Em outro estudo, Taga *et al.* (1991) propuseram um modelo neural que usava a dinâmica não linear para o controle da marcha. O modelo incorporava osciladores neurais em conexão ao

movimento rítmico de elementos músculo-esqueléticos. Com este modelo, foi obtido um sistema robusto que poderia simular tanto a caminhada como a corrida humana.

Recentemente, foi desenvolvida uma representação simples da transformação vetorial entre variáveis biomecânicas na marcha (Sepulveda *et al.*, 1993). Esta representação consistiu numa rede de três camadas com treinamento supervisionado. As redes neurais permitiram relacionar o nível de atividade em dezesseis músculos, com momentos de rotação, forças, e ângulos no quadril, joelho e tornozelo. Este modelo tinha suficiente simplicidade e potencial para inspirar parte do trabalho teórico nesta tese (Capítulo 4).

2.4 POR QUE REDES NEURAIIS ?

Seria muito mais fácil controlar a marcha gerada por EENM se existisse um modelo adequado da planta. Os fatores de não linearidade e variação (da planta) no tempo não são exclusivos do sistema neuro-músculo-esquelético, podendo de alguma forma ser modelados. A propagação do estímulo elétrico do ponto de aplicação até a placa motora pode também ser modelada usando-se técnicas de teoria de cabo, já em uso a muito tempo (Rall, 1960; Rall, 1969; Ianssek e Redman, 1973; Jack *et al.*, 1983). Para o modelamento da transmissão do sinal na placa motora pode-se fazer uso de idéias obtida por Katz (1966), Kuffler (1942), Kordas (1969), entre muitos outros. Com respeito ao modelamento de músculos, existem inúmeros trabalhos, alguns dos quais são citados abaixo. O problema está em fazer a conexão entre estes fatores, a cinética e cinemática resultantes, e, principalmente, a coordenação dos milhões de elementos envolvidos até nos mais simples movimentos. A verdade é que técnicas de modelamento de movimentos não têm produzido frutos suficientes para serem usados por aqueles que querem reproduzir o comportamento do sistema sensório-motor, como pode ser visto a seguir.

2.4.1 A Atividade Muscular Relacionada à Cinética e à Cinemática

Inúmeras tentativas têm sido feitas para relacionar a atividade muscular à dinâmica do movimento produzido. Trabalhos neste sentido tiveram início em 1952 quando Inman *et al.* observaram mudanças na amplitude de sinais miográficos de acordo com variações na carga mecânica aplicada. Deste então, inúmeros estudos têm sido feitos tentando quantificar a relação entre sinais de EMG e o comportamento mecânico dos músculos.

Grande parte dos pesquisadores tem se dedicado ao estudo de movimentos envolvendo contrações ao mesmo tempo isotônicas e isométricas. Para este tipo de contração, alguns grupos têm obtido linearidade entre EMG e os momentos de rotação nas juntas (Lippold, 1952; Bouisset e Goubel, 1973; Komi, 1973; Hof e van den Berg, 1977). Já outros pesquisadores têm relatado uma relação não linear para o mesmo tipo de contração (Vrendenbregt e Rau, 1973; Komi *et al.*, 1978; Kuroda *et al.*, 1970). Alguns pesquisadores chegaram a relacionar o grau de não linearidade do sistema com o tipo de eletrodos usados. Moritany e de Vries (1978) encontraram uma relação não linear para eletrodos bipolares e uma relação linear para eletrodos unipolares. O grau de não linearidade também está relacionado ao ângulo da junta estudada (Vrendenbregt e Rau, 1973).

Muitos trabalhos têm também sido feitos com contrações isométricas-anisotônicas. Inman *et al.* (1952) relataram uma relação linear entre a envoltória da EMG e a tensão muscular. De acordo com Milner-Brown e Stein (1975), esta relação linear resulta da sequência de recrutamento das fibras musculares (fibras menores seriam recrutadas antes). Porém, se esta fosse a razão, a linearidade deveria ser observada em todos os sistemas aqui citados, o que não é o caso.

Existe também a questão da linearidade (ou não) em relação à estrutura do músculo. Bigland e Lippold (1954) sugeriram que o tecido muscular em si tem comportamento linear

durante contrações isométricas, sendo a não linearidade decorrente do comportamento quadrático do tecido tendinoso.

De qualquer forma, movimentos humanos são mais complexos que simples contrações isotônicas ou isométricas. Levando em conta esta complexidade apenas parcialmente, alguns estudos com movimentos isocinéticos têm sido feitos (e.g., Bigland e Lippold, 1954). Outra limitação neste tipo de estudo é a frequente negligência (não justificável) com os ângulos das articulações; somente suas derivadas são consideradas (Winter, 1984). O único consenso obtido é a observação de que o sinal de EMG tem maior amplitude em contrações concêntricas que em excêntricas.

Num estudo mais completo, Hatze (1978) produziu um modelo que incluía relações tensão-comprimento, frequência de ativação, número de fibras ativadas, e até mesmo concentrações de cálcio no músculo. Este estudo aplicou também a idéia do recrutamento sequencial de fibras. Porém, este estudo nada teve a adicionar ao entendimento da relação entre a atividade muscular e a dinâmica resultante. Outro estudo inconclusivo foi apresentado por Pedotti (1977). Este trabalho consistiu num estudo da relação entre EMG e momentos de rotação para as juntas das pernas durante a marcha. Mais tarde, Olney e Winter (1985), abordaram as mesmas variáveis que Pedotti, mas de maneira quantitativa. O grupo usou constantes de regressão referentes a contrações isométricas cíclicas para 'calibrar' o modelo. O modelo não teve muito sucesso; em alguns casos, ele apresentou 200% de erro nas previsões de momentos rotacionais. Mais recentemente, Hof *et al.* (1987) propuseram um modelo com equações de Hill modificadas para o músculo *triceps surae* (durante a marcha). Os resultados foram comparados com técnicas Newtonianas que incluíam o uso de dados de plataformas de força. Este modelo também gerou erros de mais de 100%.

2.4.2 Modelando a Dinâmica da Marcha

Tentativas de modelar a dinâmica dos movimentos têm usado otimização linear, entre outras técnicas. Seireg e Arvikar (1973) minimizaram tensões musculares (mais precisamente tensão/área) para calcular forças e momentos rotacionais nos membros inferiores. Este modelo gerou previsões nada realistas para as variáveis dinâmicas, talvez por que os autores não incluíram restrições em muitas das não-igualdades no modelo. Mais tarde, Crowninshield e Brand (1981) e Davy e Audu (1987) corrigiram este problema. Estes dois últimos trabalhos geraram valores mais realistas. De qualquer forma, a própria técnica de minimização da tensão/área não passa de uma conveniência matemática que até hoje não teve comprovação através de estudos fisiológicos.

Usando outras técnicas, Onyshko e Winter (1980) aplicaram equações de Lagrange para simular a marcha. O modelo consistia em sete segmentos corporais, um dos quais representava todos os membros superiores. Foram estabelecidas condições iniciais para variáveis cinemáticas e para os momentos rotacionais externos, e não foram restringidas as trajetórias. Infelizmente, este trabalho incluiu apenas uma análise qualitativa das previsões geradas (muitas, erradas). van Best *et al.* (1983) desenvolveram um modelo composto de nove segmentos. O modelo usou dados cinemáticos e de plataformas de força como referência para avaliação dos resultados. Problemas foram encontrados nas previsões dos momentos rotacionais.

Uma tentativa interessante foi apresentada por Siegler *et al.* (1982). O grupo ignorou a massa dos membros inferiores, usando molas e amortecedores em locais estratégicos para representar as propriedades inerciais do sistema. Um dos problemas associados a este trabalho (e outros do mesmo tipo) é a quantificação da viscosidade e elasticidade das articulações, e propriedades inerciais e visco-elásticas do músculo (veja alguns modelos em Winter, 1984, e Zahalak, 1992). Tradicionalmente, ao lidar com estas variáveis, os modelos

ficam indefinidos (mais variáveis do que equações). Por esta razão, o grupo de Siegler usou valores médios para propriedades musculoesqueléticas, o que praticamente invalida o modelo, já que estes valores variam no tempo.

Mais recentemente, Pandy e Berme (1988a, 1988b) desenvolveram um modelo mais detalhado composto de equações do tipo Newton-Euler para representar a dinâmica inversa da marcha humana. O modelo incluiu cinco segmentos com quatro das articulações limitadas a um grau de liberdade. Para a marcha simples, o modelo portou-se bem. No entanto, tal é sua complexidade que seu uso deve ser evitado. Além disso, Pandy e Berme não estudaram a resposta do modelo a perturbações.

2.5 RESUMO

Ao tentar controlar a marcha recíproca gerada por EENM, o pesquisador terá que lidar com um processo extremamente não linear e variável no tempo. Além disso, não existe um modelo adequado da planta que permita o uso de técnicas de controle mais tradicionais. A opção é usar algoritmos que permitam o mapeamento entre as entradas (níveis proporcionais à atividade muscular) e as saídas (cinética e cinemática) da planta. Este algoritmo pode ser usado em esquemas de controle com modelamento da planta, modelamento inverso da mesma, ou através do modelamento do operador.

Para efetuar o modelamento envolvido no controle (ou, a rigor, uma mera representação do sistema, já que apenas as entradas e saídas da planta são consideradas, sendo ignoradas as propriedades e mecanismos da planta), pode-se usar redes neurais artificiais, sistemas nebulosos, ou outras técnicas de aproximação universal. Também podem ser usadas formas alternativas de controle adaptativo (Stein, 1992). Esta tese lida apenas com o uso de redes neurais para este fim.

CAPÍTULO 3

SIMULAÇÕES COM REDES NEURAIS ARTIFICIAIS PARA A PRODUÇÃO DA MARCHA

Na geração de movimentos rítmicos sem interferência supraespinal, a medula recebe sinais aferentes que ativam, desativam, e modulam a atividade alfa-motoneural. Os sinais aferentes carregam informação relacionada (direta ou indiretamente) à posição dos membros, ao comprimento e tensão musculares, estímulos na pele, ângulos nas articulações, e, possivelmente, às derivadas destes sinais. Simplificando este processo sensorimotor, foi produzido um modelo com possíveis aplicações à restauração da marcha em pacientes medulares. Para tanto, teve-se como meta a produção do ciclo completo da marcha mediante a ativação de cinco músculos (Tabela 1) situados nos membros inferiores e essenciais à produção da marcha vista num plano sagital. As aferências simulam sinais proporcionais aos ângulos de flexão e extensão do quadril, joelho, e tornozelo. Também é incluído um sinal aferente proporcional à componente vertical da força de reação do solo. A escolha dos músculos e sinais sensoriais foi feita para permitir a fácil produção de um sistema artificial de geração da marcha numa perna, num plano sagital, usando os parâmetros do modelo. Então, foram ignoradas a componente anterior-posterior da força de reação e outras variáveis biomecânicas. Para a implementação de tal sistema artificial seriam necessários um dispositivo de EENM de cinco canais (podendo-se usar eletrodos de superfície), três eletrogoniômetros (um para cada articulação), e um sensor de pressão na sola do pé.

1	Gluteo
2	<i>Hamstrings*</i>
3	Reto Femoral
4	Tibial Anterior
5	Triceps Sural

* Formado pelos músculos semitendinoso, semimembranoso, gracilis, e biceps femoral

Tabela 1 - Grupos musculares usados no modelo neural.

A versão mais simples do modelo (Figura 8) consiste em uma rede neural de três camadas, com conectividade completa entre duas camadas adjacentes. Funções de ativação sigmoidais, limitadas por (0,1), foram usadas em todos os neurônios das camadas escondida e de saída. A camada de entrada não faz qualquer processamento. A camada escondida é responsável pela transformação sensório-motora.

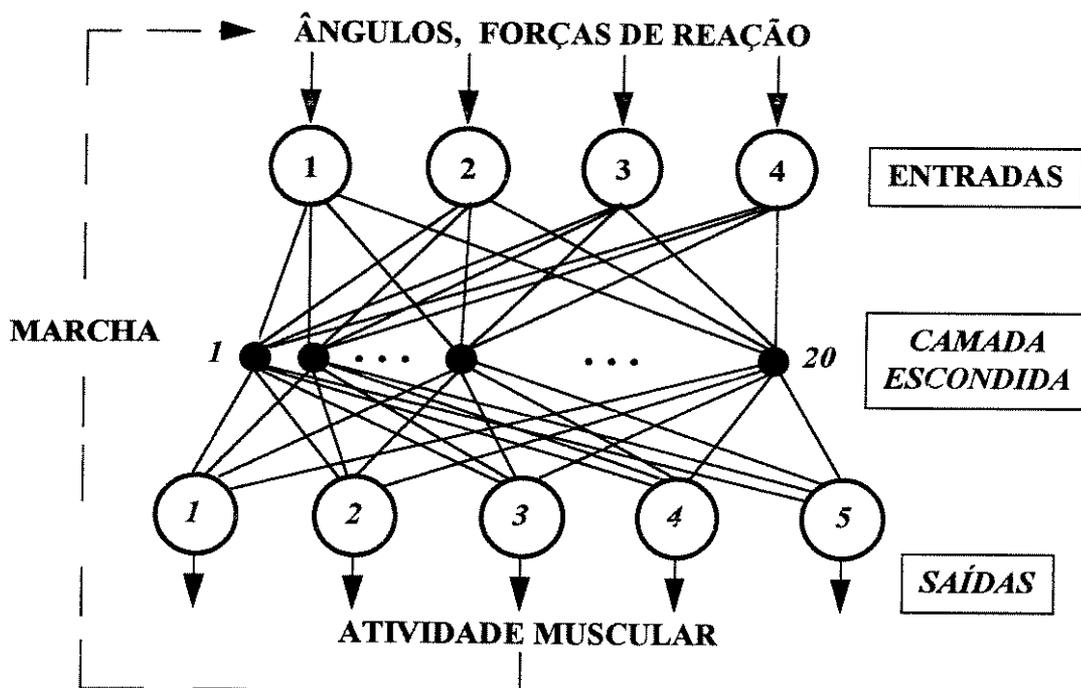


Figura 8 - Estrutura da Rede Neural 1 (Tabela 2). Todos os neurônios de entrada estão conectados com todos os neurônios escondidos. O mesmo acontece entre a camada escondida e a de saída. A linha quebrada denota o processo que fecha a malha, a marcha.

3.1 ESTRUTURA DAS REDES

Vinte e uma redes neurais (Tabela 2) foram treinadas para gerar sinais proporcionais à atividade muscular e sua derivada durante a marcha. Diferentes combinações de entradas e saídas foram consideradas para estabelecer se a rede neural artificial tem melhor desempenho ao serem incluídos os seguintes elementos no modelo:

1. Memória de estados passados
2. Considerar a última saída como entrada
3. Recursão no algoritmo de aprendizado
4. Conectividade seletiva entre as camadas escondida e de saída
5. Derivadas dos sinais de entrada e de saída
6. Uma rede para o ciclo de marcha completo *versus* uma rede para a fase de apoio e outra para a fase de balanço.

A maioria das redes tem vinte (20) neurônios na camada escondida. As exceções são aquelas que têm conectividade seletiva entre as camadas escondida e de saída (Figura 9). Neste último caso, há trinta (30) neurônios intermediários. Dez dos neurônios ativam músculos que movimentam o quadril (Gluteo, *Hamstrings*, e Reto Femoral). Outros dez ativam músculos ligados ao joelho (*Hamstrings*, e Reto Femoral), e finalmente, os dez neurônios restantes ativam os músculos que atuam no tornozelo (Tibial Anterior e Triceps Sural).

REDE	ENTRADAS	COMENTÁRIO
1	Ângulos, FR	CC
2	Ângulos, FR, última saída	CC
3	Ângulos, FR (atual+último vetor)	CC
4	Ângulos, FR	CC, RR
5	Ângulos, FR	A
6	Ângulos, FR	B
7	Ângulos, FR, última saída	A
8	Ângulos, FR, última saída	B
9	Ângulos, FR (atual+último vetor)	A
10	Ângulos, FR (atual+último vetor)	B
11	Ângulos, FR (atual+ 2 últimos vetores)	A, SL
12	Ângulos, FR (atual+ 2 últimos vetores)	B, SL
13	Ângulos, FR, última saída	A, SL
14	Ângulos, FR, última saída	B, SL
15	Ângulos, FR, última saída	A, RR
16	Ângulos, FR, última saída	B, RR
17	Ângulos, FR + (derivadas dos ângulos e FR)	CC
18	Ângulos, FR	CC; Saída: derivada da atividade muscular
19	Ângulos, FR	CC, RR; Saída: der. at. musc.
20	Ângulos, FR	CC, IE
21	Ângulos, FR	CC, IE, SL

Tabela 2 - Redes neurais testadas. FR = forças de reação; CC = ciclo de marcha completo; A = somente fase de apoio; B = fase de balanço; SL = conectividade seletiva; IE = intraconectividade na camada escondida. As redes foram treinadas com a retro-propagação tradicional, com a exceção daquelas marcadas com RR, que incluem recursão no algoritmo.

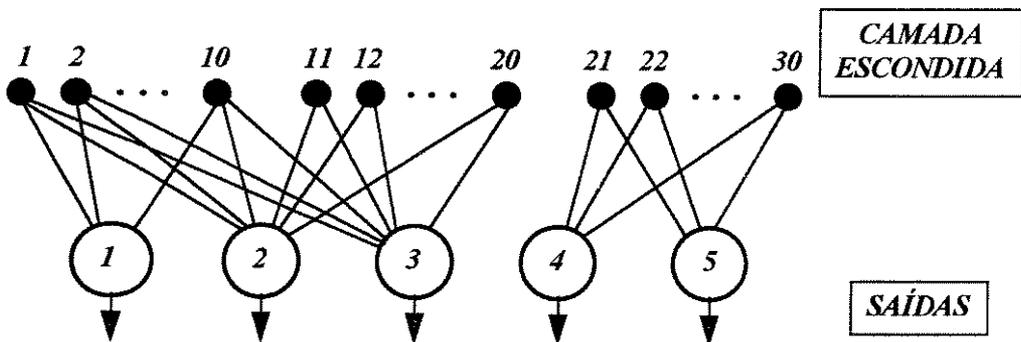
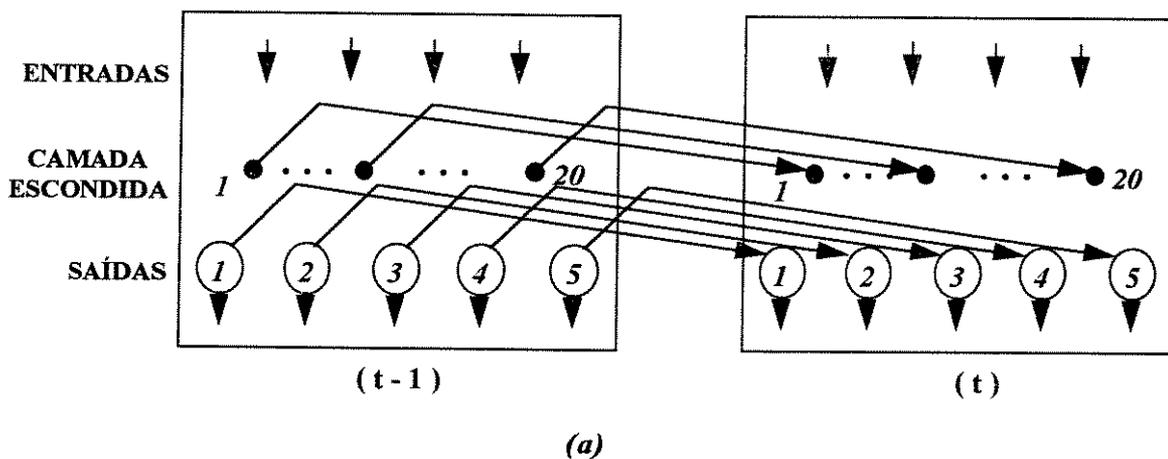


Figura 9 - Conexões seletivas entre a camada escondida (transformação sensório-motora) e camada de saída (atividade muscular, análoga às fibras alfa-motoneurais). Para a numeração das saídas, veja a Tabela 1.

No caso das redes com recursão (RR) e daquelas com intraconectividade na camada escondida (IE) há conexões adicionais nas redes neurais. Nos caso das redes com RR, as conexões existem no tempo (Figura 10a), já as redes com IE, têm conexões entre todos os neurônios da camada escondida (Figura 10b).



CAMADA ESCONDIDA

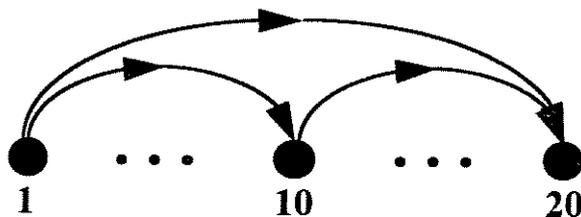


Figura 10 - Conexões adicionais em redes com recursão e intraconectividade escondida (com respeito às redes mostradas nas Figuras 8 e 9 acima). (a) redes com recursão. Neurônios das camadas escondida e de saída recebem a saída prévia deles mesmos (e somente deles mesmos) como entrada adicional ($t =$ tempo). (b) em redes com intraconectividade na camada escondida, a resposta de um neurônio afeta todos os neurônios que o seguem.

3.2 TREINAMENTO DAS REDES

Para o treinamento da maioria das redes foi usado um algoritmo de retro-propagação instantânea (Apêndice A) tradicional (Rumelhart *et al.*, 1986b). Para o treinamento das redes com recursão foi usada a retro-propagação através do tempo (Werbos, 1990). Em ambos os casos, foi incluído um termo de tendência (*bias*) variável referente a cada neurônio.

Para efeito de treinamento, o ciclo da marcha foi dividido em vinte (20) quadros (os dados de treinamento são apresentados na próxima seção). Cada quadro representa um par de entradas e saídas para a rede neural. Na entrada das redes foi apresentado um vetor com elementos proporcionais aos ângulos e à força de reação gerados por uma determinada atividade muscular num determinado momento t . As saídas da rede geram valores proporcionais à atividade muscular referente a $t+1$, necessária para prosseguir o movimento.

Os pesos sinápticos foram inicializados aleatoriamente. Os limites do domínio original dos pesos foram estabelecido por tentativa e erro. A faixa inicial situava-se em $(-2,+2)$, mas esta foi sendo modificada para cada rede até que fosse alcançado um aprendizado mais rápido (menor número de iterações até atingir um determinado nível de erro; cada iteração é a apresentação de todo o conjunto de treinamento, não apenas um par entrada-saída). O mesmo ajuste foi feito com respeito ao *bias*.

Foi usada uma tolerância de 0.1 no treinamento de todas as redes. Isto significa que para saídas-meta em $(0,1)$, o erro máximo aceito para qualquer saída é 0.1. Geralmente, este valor (assim como o número de neurônios na camada escondida) é escolhido arbitrariamente. Entretanto, um valor maior que 0.1 dá uma margem de erro muito grande à rede, ao passo que um valor inferior a 0.1 diminui a capacidade de generalização da rede depois do aprendizado (há exceções a esta regra informal, como é o caso mostrado no próximo capítulo).

Para evitar que a rede entre em mínimos locais não aceitáveis, foi concebida a seguinte estratégia de manipulação da taxa de aprendizado \mathcal{R} :

- ♦ Se o número de saídas erradas (erro maior que a tolerância) é maior que $2/3$ do número total de saídas (considera-se o conjunto completo de pares de entradas e saídas), $\mathcal{R} = c$, onde c é uma constante (geralmente $= 1$).
- ♦ Se o número de saídas erradas é menor que $2/3$ do número total de saídas, a taxa de aprendizado é dada por $\mathcal{R} = a / (\text{número total de saídas} + 1)$, onde a é uma constante (geralmente $\leq c$).
- ♦ Se o número de saídas erradas mantém-se sem modificações por mais de m iterações, $\mathcal{R} = 2c$, onde geralmente $m = 1000$.
- ♦ Se o número de saídas erradas mantém-se sem modificações por mais de n iterações, $\mathcal{R} = c$, e os pesos sinápticos são reinicializados aleatoriamente. n geralmente é igual a $4m$.

Usa-se o termo 'geralmente' com frequência porque pequenos ajustes foram feitos em algumas redes de acordo com a aparente velocidade de aprendizado (o método de tentativa e erro é bastante popular entre aqueles que lidam com redes neurais artificiais).

Para a avaliação das redes usando a menor média dos quadrados dos erros (veja próximas sessões), dois terços do ciclo da marcha foram usados no treinamento (os quadros de números múltiplos de três foram usados para testes após o treinamento). Para a simulação patológica, as redes foram treinadas com todo o conjunto de dados normais.

3.3 DADOS PARA O TREINAMENTO E AVALIAÇÃO DO

DESEMPENHO DAS REDES NEURAIIS

As redes neurais foram treinadas com uma base de dados de uma pessoa normal. Os dados para o treinamento e avaliação foram extraídos de Winter (1987) e Vaughan *et al.* (1992).

O ciclo da marcha foi dividido em vinte (20) quadros. Ou seja, há vinte pares entrada-saída. Destes vinte quadros, quatorze (14) foram usados no treinamento para a avaliação pela menor média do quadrado dos erros. Os outros seis (6) quadros foram usados nos testes. Para acelerar o aprendizado, tanto os dados de entrada como os dados de saída meta foram normalizados para caber na faixa (0.2, 0.8). Isto é feito porque, quando é usada uma função sigmoideal no domínio (0, 1), o aprendizado é mais rápido se os dados estão mais perto da região central da função (0.5), onde a derivada atinge seu valor máximo. Perto de 0.0 ou de 1.0, a derivada da função sigmoideal tende a zero, fazendo com que as mudanças nos pesos sinápticos também tendam a zero (neste caso, a rede converge até a tolerância somente após um tempo tendendo ao infinito). Por outro lado, devido à tolerância de 0.1, os dados não podem ficar muito próximos a 0.5.

Os dados de entrada são mostrados na Figura 11. As metas para as saídas estão na Figura 12. Os dados na Figura 12 consistem de sinais eletromiográficos normalizados (as fontes originais dão a envoltória linear da EMG) com o devido adiantamento de fase em 5% do ciclo. Este adiantamento deve-se ao fato de que as redes devem usar os ângulos e forças de reação de um quadro para prever a atividade muscular necessária para o quadro seguinte.

Para fazer um modelo mais rigoroso, as redes deveriam ser treinadas para dar uma resposta proporcional ao sinal dos motoneurônios alfa. Infelizmente estes dados não existem na literatura. A solução encontrada foi usar os dados que mais e aproximam, ou seja, sinais

eletromiográficos. Para efeito de modelamento, então, presume-se ser linear o mapeamento da atividade motoneural para a atividade miográfica.

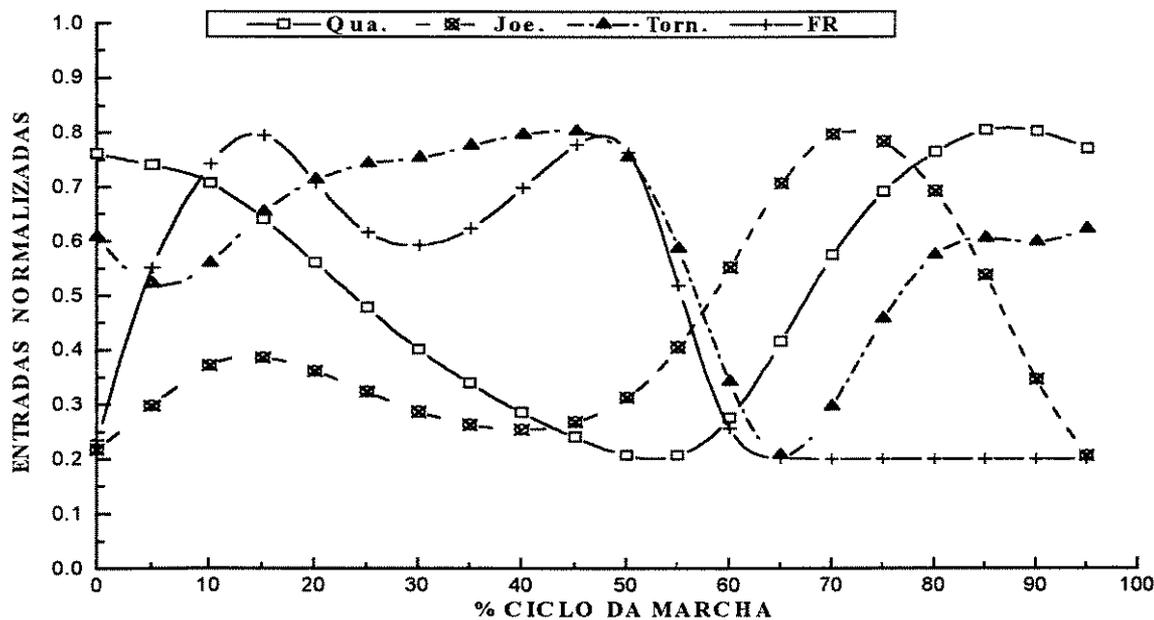


Figura 11 - Dados de entrada para o treinamento das redes. Qua. = ângulo do quadril. Joe. = ângulo do joelho. Torn. = ângulo do tornozelo. FR = força de reação vertical. A cada 5% do ciclo é extraído um vetor de entrada. Para os ângulos, valores crescentes indicam flexão (dorsiflexão para o tornozelo)

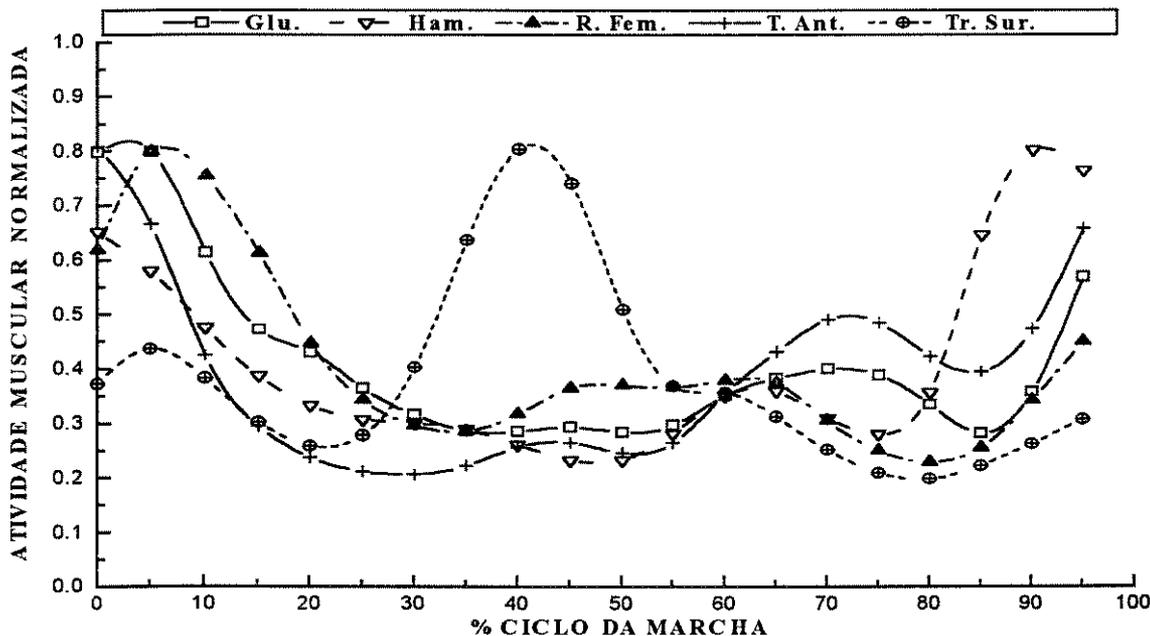


Figura 12 - Saídas meta para o treinamento das redes. Os dados mostrados já têm um adiantamento de 5% na fase.

Para a simulação de um caso patológico foram usados os dados da marcha de um paciente com paralisia cerebral (Vaughan, 1992). Neste caso, às redes treinadas com os dados normais acima, foram apresentados dados de entrada referentes ao caso patológico (Figura 13). A resposta da redes foi então comparada aos verdadeiros valores de atividade muscular obtidos do paciente (Figura 14). Os dados patológicos também foram normalizados em (0.2, 0.8).

No processo de normalização dos dados (normais e patológicos), cada sinal foi comprimido individualmente com respeito aos seus valores máximos e mínimos. Ao fazer isto, ao contrário do uso de mínimos e máximos globais, considera-se que nenhum sinal é mais importante que outro. No caso das atividades musculares, isto equivale a dizer que todos os músculos no modelo têm a mesma importância, independente das diferenças na amplitude miográfica medida.

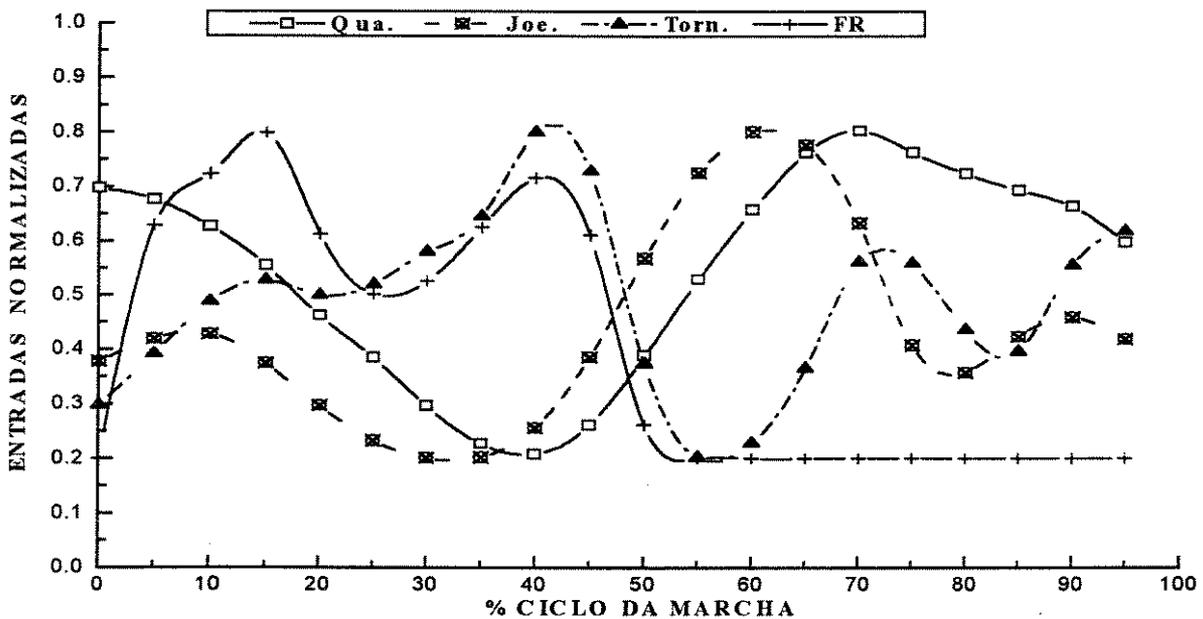


Figura 13 - Dados patológicos de entrada extraídos de Vaughan (1992). Foi aplicada a normalização em (0.2, 0.8). A porcentagem do ciclo da marcha tem como referência a duração do ciclo em uma pessoa normal.

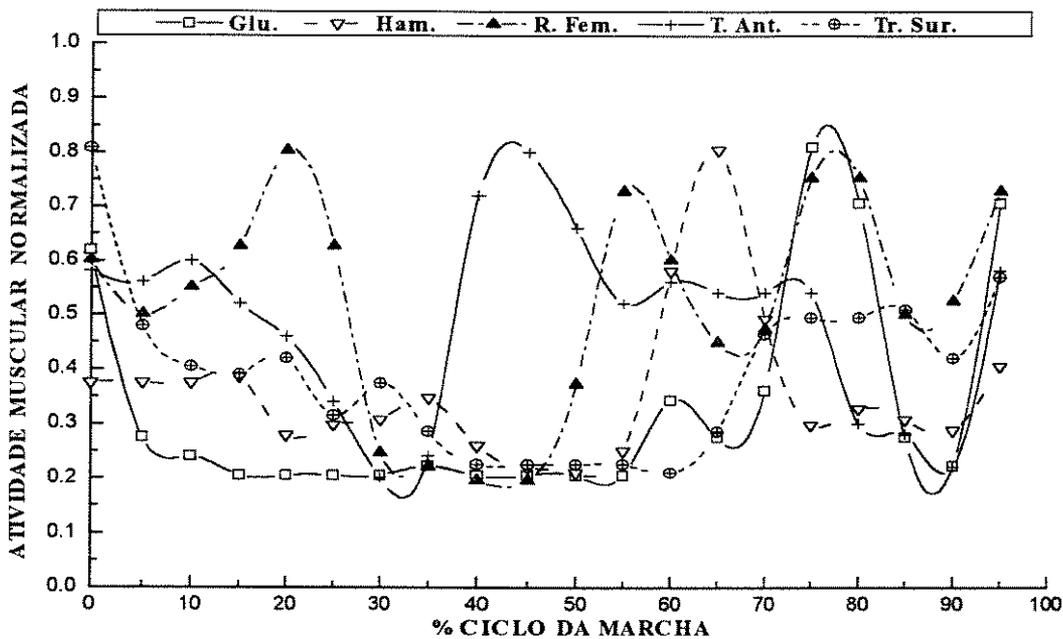


Figura 14 - Atividades musculares normalizadas referentes ao caso patológico. Os dados já incluem o adiantamento da fase em 5% do ciclo.

3.4 AVALIAÇÃO DO DESEMPENHO DAS REDES

3.4.1 Menor Média dos Quadrados dos Erros (MQE)

Para o teste de MQE, 1/3 dos dados de entrada normais (os quadros não usados para o treinamento) foram apresentados às redes neurais (segundo Brown e Harris, 1994). A resposta das redes (já treinadas) foi então comparada com os valores verdadeiros (incluídos na Figura 12) da seguinte maneira:

1. Para cada neurônio i ($i = 1, \dots, 5$) de saída, e para cada quadro de teste j , foi calculado o quadrado do erro $(E_{i,j})^2 = (R_{i,j} - V_{i,j})^2$, onde R é a resposta do neurônio e V é saída verdadeira.
2. Foi então calculada a média dos quadrados dos erros para cada quadro j , $MQE_j =$

$$\frac{1}{5} \sum_{i=1}^5 (E_{i,j})^2.$$

3. Ainda, foi calculada a MQE média para a fase de apoio, (MQE_A), para a fase de balanço (MQE_B), e para o ciclo completo (MQE_{CC}), da seguinte maneira:

$$MQE_A = \frac{1}{K} \sum_{j=1}^K (MQE_j), \quad \text{onde } K \text{ é o número de quadros de teste na fase}$$

de apoio,

$$MQE_B = \frac{1}{L} \sum_{j=1}^L (MQE_j), \quad \text{onde } L \text{ é o número de quadros de teste na fase de}$$

balanço, e

$$MQE_{CC} = \frac{1}{m} \sum_{j=1}^m (MQE_j), \quad \text{onde } m = K + L.$$

Nestas simulações, $K = 4$, $L = 2$, e $m = 6$.

Os valores de MQE_A , MQE_B , e MQE_{CC} obtidos para cada rede foram comparados

(junto com os coeficientes de correlação, a seguir).

3.4.2 Simulação Patológica

Nesta simulação, deseja-se saber se uma rede treinada com dados normais pode ser usada para o controle de uma situação patológica. Neste caso, as redes foram treinadas com os vinte (20) quadros mostrados nas Figuras 11 e 12. Nos testes, os dados da Figura 13 foram usados como entrada, e a resposta das redes foi comparada aos dados da Figura 14.

Para avaliar qual das redes neurais tem melhor desempenho, dois testes foram feitos. Primeiro, foram calculados MQE_A , MQE_B , e MQE_{CC} , sendo que neste caso $K=12$, $L=8$, e $m=20$. Além disso, foi calculado o coeficiente de correlação de Pearson referente a cada músculo, da seguinte maneira:

1. Para cada músculo i são definidos dois vetores referentes ao ciclo completo da marcha: v = vetor previsto pelas redes, e z = vetor verdadeiro (correspondente a cada curva na Figura 14).

2. Então, para $n = 20$, foi calculado o coeficiente de correlação crc :

$$crc(v, z) = \frac{\sum_j^n (v_j - mv)(z_j - mz)}{\sqrt{\sum_j^n (v_j - mv)^2 \sum_j^n (z_j - mz)^2}},$$

onde

$$mv = \frac{1}{n} \sum_j^n v_j,$$

$$mz = \frac{1}{n} \sum_j^n z_j, \text{ e } j \text{ é o número do quadro.}$$

O coeficiente de correlação médio incluindo o ciclo completo da marcha e todos os

músculos, crc_{CC} , obtido para cada rede ($crc_{CC} = \frac{1}{5} \sum_{i=1}^5 crc_i$, onde 5 é o número de músculos)

foi usado para avaliar o desempenho. Também foram calculados valores médios para a fase de apoio (crc_A , sendo $j=1, \dots, 12$, acima), e para a fase de balanço (crc_B , sendo $j=13, \dots, 20$)

A comparação entre as redes foi baseada nos valores de crc_{CC} , crc_A , e crc_B obtidos para cada rede. Ao usar-se o coeficiente de correlação de Pearson, a melhor performance é aquela que mais se aproxima a $crc=+1$ (um valor de -1 denota curvas simetricamente com respeito a um eixo horizontal).

3.5 ASPECTOS GERAIS

Para as simulações e treinamento das redes foram desenvolvidos programas em Turbo Pascal (BorlandTM) que incluíam rotinas para monitoração gráfica das saídas das redes

neurais e das curvas meta. A maior parte das simulações foi feita em um PC-AT 486/66MHz e em um 486/100MHz. Inicialmente, versões do algoritmo de treinamento foram feitas em FORTRAN e em C, para rodar numa estação de trabalho SPARC 4, mas a velocidade desta máquina não resultou ser muito superior à dos 486s. Então, somente a versão Pascal continuou sendo usada.

CAPÍTULO 4

SISTEMA EXPERIMENTAL

No sistema experimental usou-se um esquema de controle baseado no modelamento do operador (veja Capítulo 2). Três testes piloto foram feitos com o sistema, um teste no Brasil e dois na Escócia. O sistema experimental final incluiu aprendizado ‘off-line’ e aprendizado ‘on-line’ com reforço positivo e negativo. Toda a confecção e testes com o sistema final foram feitos na Unidade de Bioengenharia da Universidade de Strathclyde, em Glasgow.

4.1 ESQUEMAS DE CONTROLE

Foi usada uma rede neural artificial de três camadas, com interconectividade completa entre camadas adjacentes (veja Figura 8, Capítulo 3). Nas entradas foram usados sinais normalizados referentes aos ângulos do quadril, joelho, e tornozelo (as juntas monitoradas variam de um sistema para outro, veja próximas sessões). A saída para um dos sistemas (Teste Piloto 1) consistia em variações na tensão aplicada na EENM para o ciclo completo da marcha. Para todos os outros testes, a saída determinava variações na largura do pulso aplicado (LP) durante a fase de balanço. O tipo de saída usada foi determinado pelo equipamento disponível. O esquema de controle ilustrado abaixo é baseado no sistema de variação da largura do pulso durante a fase de balanço.

Foi modelado o comportamento de um operador humano (Figura 15). Enquanto o operador modificava o sinal de EENM baseado no movimento resultante observado (saída da

planta), tanto as saídas da planta como as modificações feitas na LP foram gravadas em arquivos. Estes arquivos foram usados para o treinamento da rede neural por meio da retropropagação. Cada par de treinamento consistia em um vetor de ângulos observados (saída da planta = entrada da rede neural) e um vetor de mudança na LP (saída da rede = sinal de controle da planta). Cada vetor consiste em dados de todo o movimento de balanço.

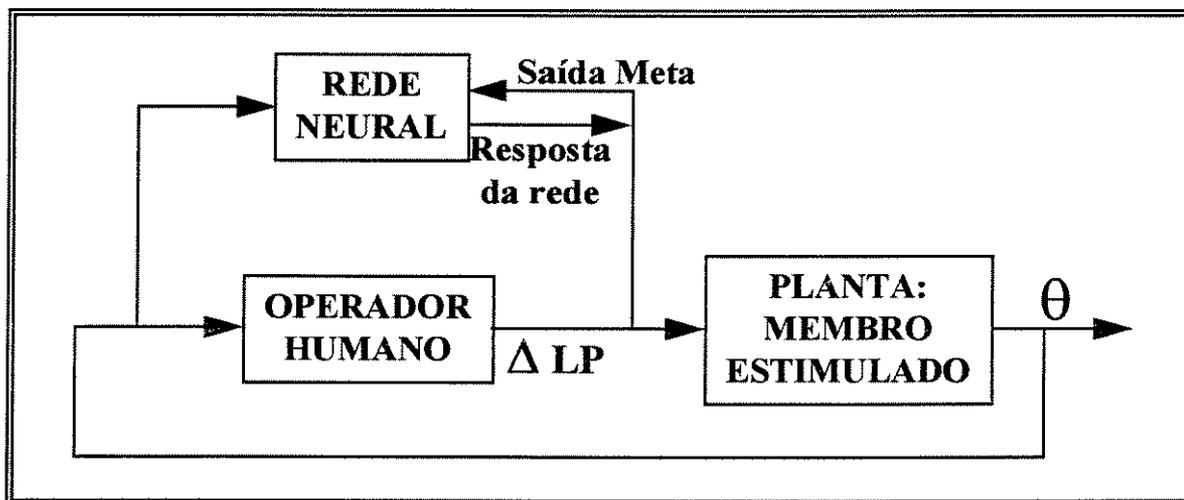


Figura 15 - Esquema de controle da EENM baseado no modelamento do operador especialista. A figura mostra o esquema de treinamento off-line. θ = ângulos das juntas.

Muitas das modificações feitas na LP foram propositadamente erradas, para produzir movimentos inadequados. Após obtido o movimento inadequado, valores corretos de LP foram usados. Isto, ao menos teoricamente, permite que a rede neural aprenda a recuperar-se de seus próprios erros (mais será dito sobre o treinamento da rede neural nas próximas sessões).

Após treinar a rede neural de modo 'off-line' para simular o operador, a rede foi usada em modo automático, substituindo o operador (Figura 16). Mais tarde, o sistema experimental incluiu aprendizado 'on-line' (Figura 17). O aprendizado 'on-line' aplica reforço positivo e negativo.

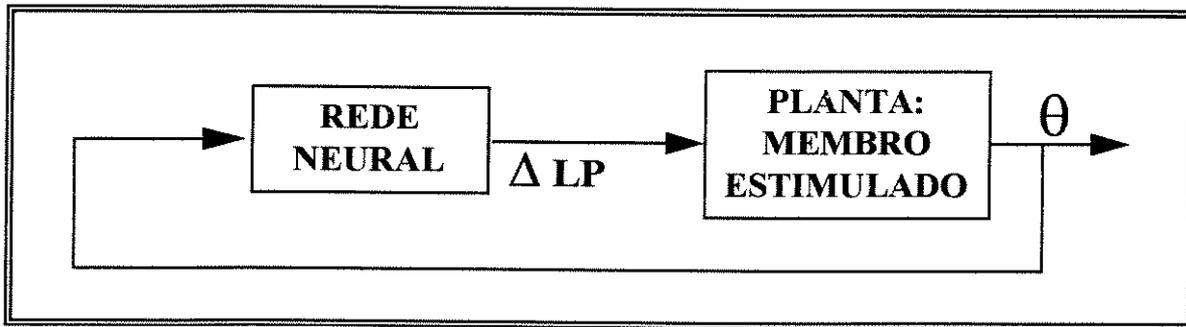


Figura 16 - Controle da largura de pulso aplicada por uma rede neural durante a fase de balanço.

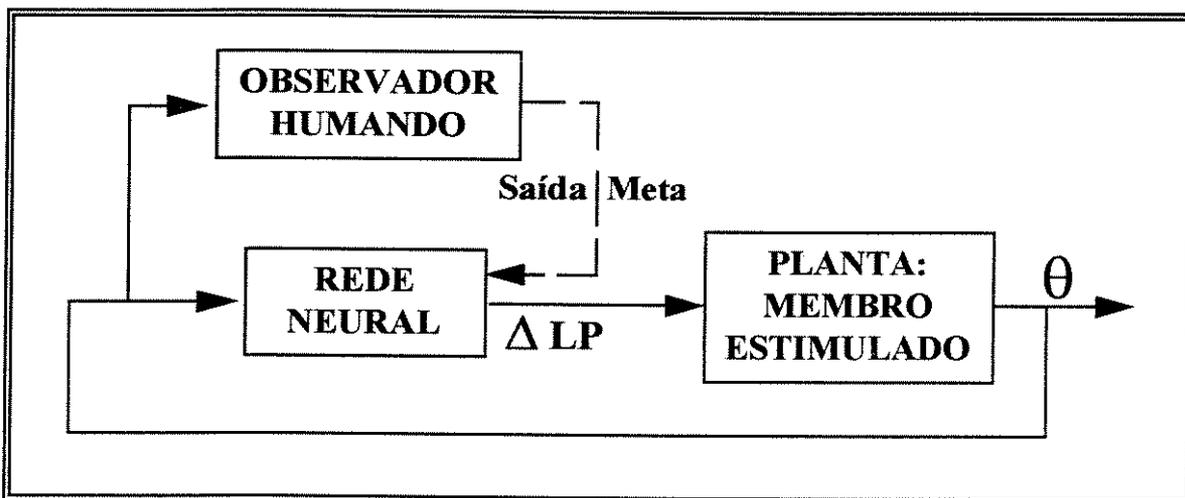


Figura 17 - Esquema de controle incluindo aprendizado 'on-line'. O aprendizado, por meio de reforço positivo e negativo (veja restante do capítulo), ocorre somente quando o observador julgar necessário. Para reduzir a demanda computacional do sistema, o aprendizado 'on-line' ocorre durante a fase de apoio, quando a EENM usa valores predeterminados.

4.2 EQUIPAMENTOS

4.2.1 Teste Piloto 1

Para o Teste Piloto 1, realizado no Brasil, foi usado um estimulador portátil de tensão variável de 0V a 128V ($1\text{ k}\Omega$) e dois canais de saída. Este estimulador teve sua saída controlada por um software, produzido em linguagem C, por meio de um computador do tipo PC-XT com co-processador numérico. O mesmo software de controle fazia a leitura dos sensores e treinamento da rede neural. Neste teste foram usados um eletrogoniômetro no joelho da perna estimulada e dois sensores de força do tipo FSR na sola do pé (Figura 18). Os sensores FSR foram comprados da Interlink Inc., USA; o restante do equipamento foi produzido por membros do grupo de Engenharia de Reabilitação, DEB - UniCamp.

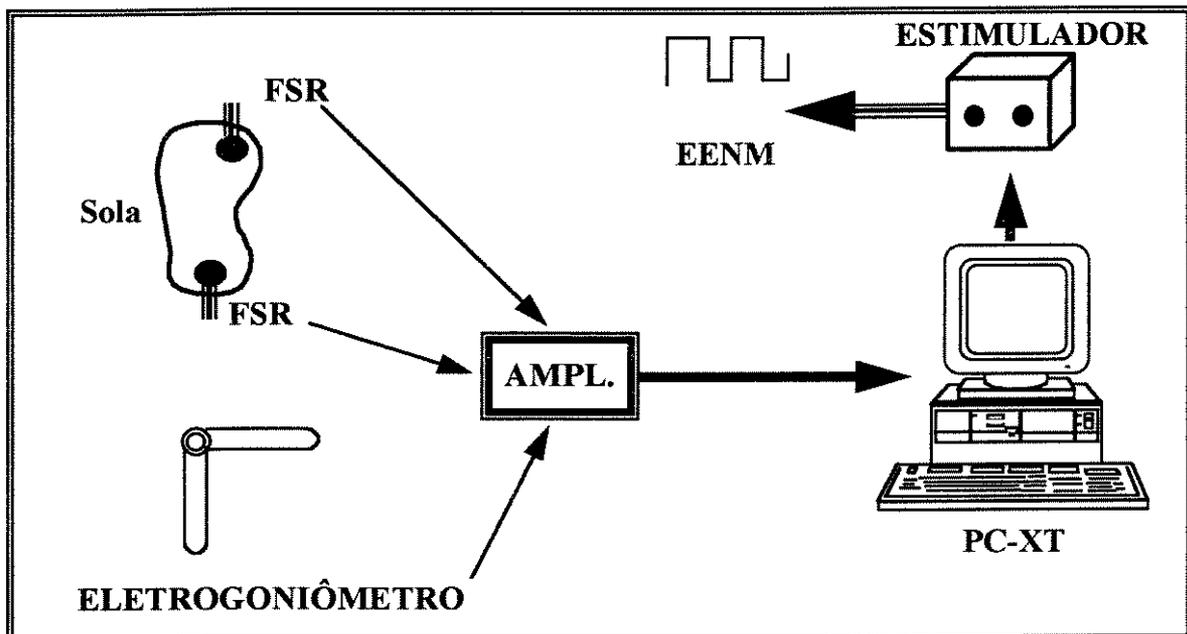


Figure 18 - Esquemático do equipamento usado no Teste Piloto 1.

4.2.2 Outros Testes

No sistema desenvolvido em Glasgow foi usado o estimulador **Strathclyde Research Stimulator** (Figura 19). Este estimulador tem oito canais de saída e é controlado por computador. Para o controle do estimulador, foi usado um computador CompaqTM AT-12MHz. Com este estimulador, é possível variar a frequência e largura de pulso da estimulação, assim como a duração do trem de estímulo via computador. A amplitude da tensão tem que ser ajustada manualmente, e a grosso modo. A tensão máxima de saída é 180V (1 k Ω) e a corrente aplicada é constante para LP < 0.5 ms. A LP máxima é de 2.0 ms. O estimulador é acoplado a uma bateria de 6V. Os sensores usados foram dois eletrogoniômetros flexíveis (Figura 20) produzidos por Penny & Giles, Inc. (UK). Estes goniômetros requerem o uso de um amplificador de ponte. O sinal proveniente deste amplificador é enviado ao computador junto com o sinal de dois interruptores usados manualmente no sistema final. Para as entradas e saídas, o computador é equipado com uma placa conversora A/D e uma placa de I/O produzidos por Amplicom Liveline Ltd. (UK). Para permitir o fácil transporte de todo este material dentro do laboratório, usou-se um carrinho. Este é empurrado em direção ao paciente quando o comprimento dos cabos não é mais suficiente (veja Figura 21). Para o treinamento 'off-line' das redes foi usado um Pentium-75MHz, e um 486-66MHz.

Foram usados eletrodos de superfície PALS[®] reusáveis (Nidd Valley Micro Products Ltd., UK) com diâmetros de 2.54 cm a 7.62 cm. Para suporte do paciente foi usado um sistema de barras paralelas.

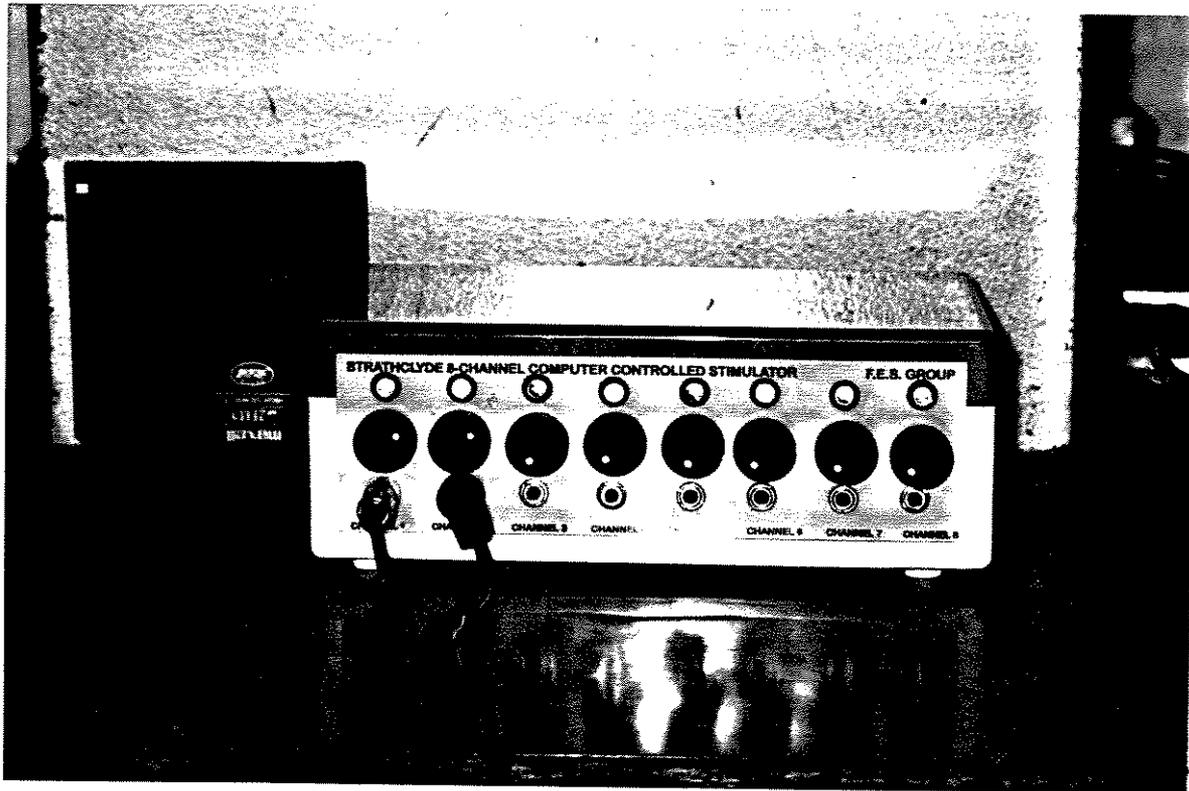


Figura 19 - Estimulador de oito canais.

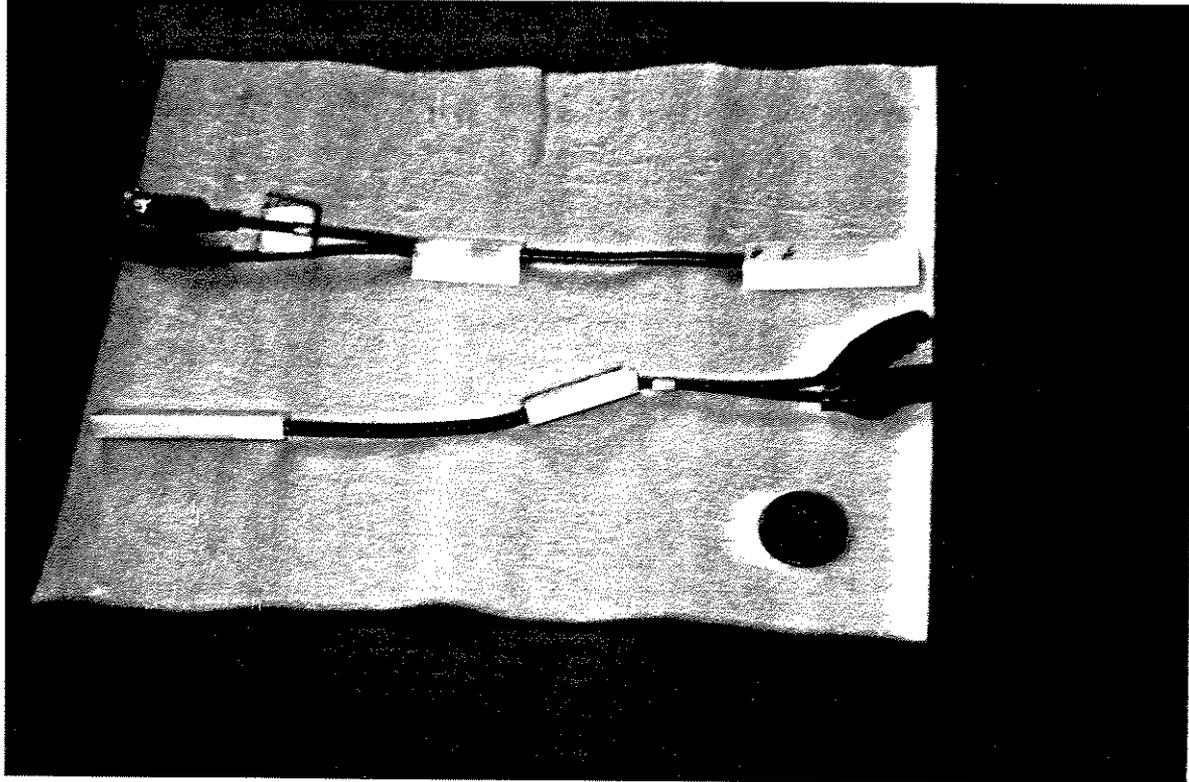


Figura 20 - Eletrogoniômetros flexíveis usados para medir os ângulos das articulações. Estes goniômetros são de fácil colocação; basta usar uma fita com ambas as superfícies adesivas para colocar um dos elementos de fixação (volume branco na foto) distal à articulação de interesse e outro proximal a ela. Os volumes pretos nas extremidades dos goniômetros são as saídas através das quais o sinal é medido. Há dois canais: um para medir flexão/extensão do goniômetro, e outro para medir torção ao redor do eixo longitudinal.

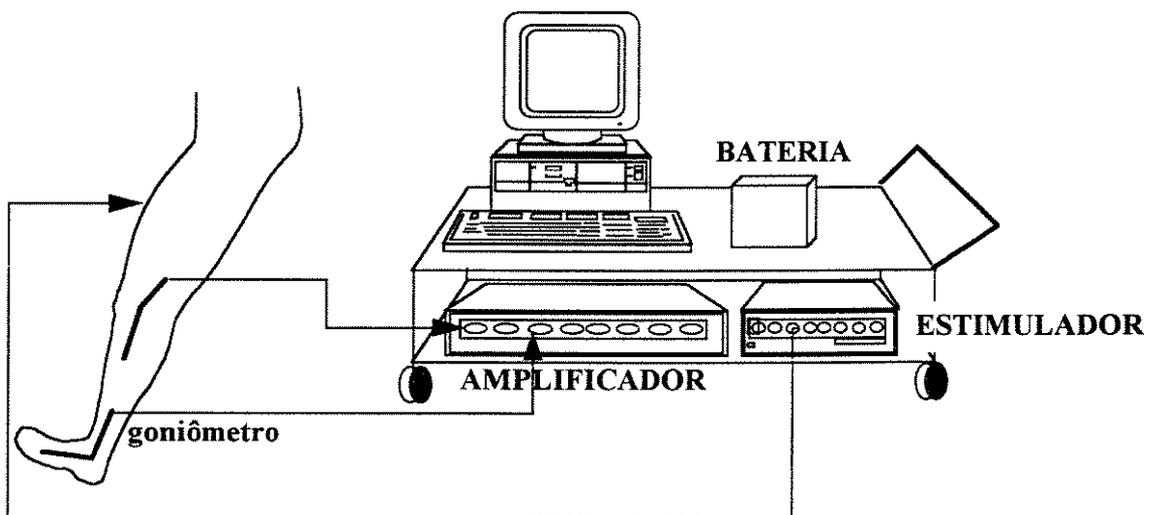


Figura 21 - Esquema de todo o equipamento usado para testes do sistema experimental.

4.3 PROCEDIMENTO: TESTES PILOTO

4.3.1 Teste Piloto 1

O Teste Piloto 1 foi feito com uma paciente tetraplégica (nível C6, lesão completa), 24 anos de idade. Foi aplicada EENM no nervo femoral (para produzir contração do quadríceps) e no nervo peroneal comum (para gerar o reflexo de retirada) da perna esquerda. Neste primeiro teste, a paciente manteve-se sentada por questões de segurança. Movimentos simulando passos da marcha foram produzidos via EENM.

A estimulação foi aplicada em três fases:

1. $t =$ indefinido, estimulação do quadríceps (fase de apoio)
2. $t = 2s$, estimulação do nervo peroneal (início do balanço)
3. $t = 2s$, estimulação femoral e peroneal (conclusão do balanço)

A fase 2 é ativada por meio de um interruptor manual.

Na primeira versão deste sistema, foram usados sinais provenientes dos sensores na sola do pé e do goniômetro colocado no joelho esquerdo. A rede neural foi então treinada para controlar a intensidade da estimulação nas três fases acima. No entanto, com frequência a rede neural aplicou uma intensidade muito baixa (às vezes nula) durante a fase de apoio. Não estivesse a paciente sentada, isto teria causado uma queda. Por esta razão foi removido o controle da estimulação por meio da rede neural na fase 1. Isto também resultou na remoção dos sensores de força na sola do pé, agora não mais necessários, já que o controle passou a ser em malha fechada somente na fase de balanço (quando o sinal proveniente dos sensores de força é nulo).

O sistema, agora com estimulação fixa para a fase de apoio, foi então treinado com 13 pares de entradas e saídas. Cada vetor de entrada consistiu em valores referentes ao ângulo do joelho para as fases 2 e 3 acima. A amostragem foi feita em 6Hz (a maior parte do sinal se encontra abaixo de 2Hz). Para os quatro segundos de estimulação controlada, isto significa que o vetor de entrada tinha 24 elementos. O vetor de saída continha apenas dois elementos, determinando as variações a serem produzidas na intensidade da estimulação nos canais femoral e peroneal. Os valores eram ajustados apenas uma vez para todo o ciclo.

Para o treinamento da rede foi executado o seguinte processo:

- I. Foram definidos valores arbitrariamente baixos para os dois canais de estimulação.
- II. Ajustes foram feitos em direção a uma combinação ótima na estimulação (a julgar pelo movimento observado).
- III. Uma vez encontrada a combinação ideal, variações deliberadamente erradas foram feitas na estimulação.
- IV. Tanto os valores obtidos do goniômetro como os valores usados para a estimulação nas etapas I, II, e III foram gravados em arquivos.

V. A rede neural foi então treinada tendo como entrada o vetor com os 24 valores proporcionais aos ângulos, e como saída meta a **diferença** entre a estimulação ideal e cada uma das outras combinações usadas.

Considerando que a rede neural usada tem funções de ativação sigmoidais com valores em (0, 1), o seguinte mapeamento foi feito entre as saídas da rede neural e a intensidade da estimulação (a faixa útil da estimulação era de 38V a 128V):

- Para um valor de saída de 0.5, nenhuma modificação é feita no canal correspondente.

- Saídas <0.5 resultam numa redução da intensidade segundo:

$\Delta A = 90V (saída - 0.5) / 0.5$, onde **A** é a tensão aplicada. O valor 90V é a faixa útil de variação do sinal (128V - 38V). Para uma tensão < 38V, não foi observada a contração muscular. 128V era a saída máxima do estimulador.

- Para saída > 0.5, a expressão acima resulta em variações positivas, ou seja, em aumento da estimulação.

- Para manter o sistema dentro da faixa útil, o seguinte artifício foi adotado:

se ΔA resulta numa tensão < 38V, tensão = 38V; se ΔA resulta numa tensão > 128V, tensão = 128V.

(O uso deste último artifício impossibilita uma análise da estabilidade do controle).

No treinamento, o par representando o ciclo ideal tinha na entrada os ângulos, e na saída o valor 0.5 para ambos canais. Desta maneira, a rede neural (teoricamente) aprende a gerar variações na estimulação em direção a uma combinação ideal. Foi usada uma tolerância de 0.02.

A rede neural não foi treinada para gerar valores absolutos de estimulação, por uma razão muito simples: valores absolutos de EENM variam muito mesmo durante uma mesma sessão de testes. A rede neural é treinada para fazer aquilo que o operador humano faz: aumentar ou diminuir a intensidade do sinal até que um movimento adequado seja observado.

Após o treinamento da rede, o sistema foi usado no controle automático de 12 ciclos de estimulação (equivalente a 12 passos). O processo de avanço na rede neural treinada é feito durante a fase de apoio. Para avaliar o comportamento da rede neural, os valores da estimulação aplicada foram comparados àquela que seria a combinação ideal para a sessão de testes (determinada manualmente pelo operador).

Para o Teste Piloto 1 foi feito um programa em linguagem C denominado NNW2.1 (Neural NetWalk 2.1). (Uma listagem do programa pode ser requisitada ao endereço eletrônico francisc@deb.fee.unicamp.br). Este programa inclui as rotinas de treinamento da rede neural.

4.3.2 Teste Piloto 2

O teste foi feito com um paciente com lesão incompleta a nível C6. O paciente tem 32 anos de idade e pode manter-se em pé com a ajuda de muletas ou barras paralelas mediante suporte (ainda que frágil) sobre a perna direita. O paciente não tem qualquer controle voluntário da perna esquerda.

Foram usados um interruptor manual (para iniciar a fase de balanço) e dois goniômetros flexíveis (para o joelho e para o tornozelo). O esquema usado para o treinamento da rede foi o mesmo do Teste Piloto 1 acima. Neste caso, entretanto, a rede neural foi treinada para gerar variações na largura de pulso (LP) do estímulo. A faixa útil da LP era de 40 μ s a 2.0 ms. No entanto, a LP máxima foi fixada em 1.0 ms para não causar fadiga excessiva. A frequência do estímulo foi fixada em 25Hz.

A estimulação seguiu a sequência usada no Teste Piloto 1. A largura de pulso aplicada na fase de apoio foi prefixada. A amostragem foi feita em 6Hz (baseado numa FFT do sinal, veja Capítulo 6). Foram obtidos quinze ciclos de exemplo. Destes, 12 foram usados para o treinamento da rede neural. Os três restantes (escolhidos aleatoriamente) foram usados para testar a rede já treinada. Nos testes, foram previstas variações nas LPs baseado nos vetores de entrada. As LPs corrigidas foram comparadas aos valores ideais obtidos durante a sessão de aquisição de arquivos para o treinamento..

O paciente foi mantido em pé durante vários ciclos de estimulação para produzir movimentos similares a passos (o balanço ocorre, mas o paciente não sai do lugar). O paciente manteve-se apoiado na perna direita e em barras paralelas. A estimulação para a fase de balanço foi ativada mediante um interruptor pressionado pelo operador quando indicado pelo paciente.

Vários problemas foram encontrados neste teste (veja Capítulo 6), mas o sistema final (seção 4.4) foi baseado neste teste piloto. O teste piloto serviu também para otimizar a velocidade de treinamento da rede neural. Foram manipulados a taxa de aprendizado e a faixa inicial dos pesos sinápticos e dos termos de *bias*. Desta maneira, o sistema experimental final pôde contar com um aprendizado mais acelerado.

4.3.3 Teste Piloto 3

Este teste foi feito em um paciente hemiplégico de 65 anos de idade. Este paciente apresenta dorsiflexão fraca na perna direita. Portanto, foi estimulado o nervo peroneal para auxiliar na dorsiflexão. Foram usados um eletrogoniômetro flexível no tornozelo direito, e um interruptor na região do calcanhar direito. Este interruptor permite detectar a intenção de executar o balanço. Cabos longos foram usados neste teste, já que o paciente pôde caminhar por todo o laboratório sem a ajuda de terceiros.

Foram adquiridos setenta e sete ciclos para o treinamento da rede. A amostragem foi feita em 20Hz e dez pontos (espaçados igualmente) do sinal filtrado (suavizado usando-se a média entre dois pontos) foram usados para compor um vetor de entrada. Este procedimento foi adotado devido ao tempo variável da estimulação (ativada quando o calcanhar deixa o solo, e desativada quando o calcanhar toca o solo novamente).

Esta seria uma versão do trabalho de Liberson (1961) incorporando controle por rede neural. Mas, surgiram dúvidas sobre o verdadeiro efeito da estimulação neste paciente, já que ele tinha algum controle voluntário da dorsiflexão. Para verificar se a estimulação afetava o movimento de forma incontestável, vários ciclos de estimulação foram executados sem qualquer estimulação (sem o conhecimento do paciente). Uma análise estatística dos resultados acusou efeitos questionáveis da estimulação. Então, testes com este paciente foram abandonados.

4.4 SISTEMA EXPERIMENTAL

Foram feitas duas versões diferentes do sistema experimental final. A primeira versão, **S1**, teve ângulos do joelho e tornozelo como entrada para a rede neural. A outra versão, **S2**, utilizou ângulos do joelho e do quadril. Em ambos os sistemas, a EENM foi aplicada aos nervos femoral e peroneal comum, como visto nos Testes piloto 1 e 2 acima. Os testes foram feitos com o paciente mencionado no Teste Piloto 2.

Os sistemas **S1** e **S2** incluíram aprendizado 'on-line' ativado pelo operador. Em ambos os casos, foi avaliado o desempenho da rede neural antes, durante, e depois de aplicado o treinamento 'on-line'. Para avaliar o desempenho dos sistemas, vários ciclos de teste foram executados com valores predeterminados de largura de pulso (**LP**). Os movimentos observados foram comparados a um passo ideal obtido durante a sessão de teste.

4.4.1 Sistema 1 (S1)

Foram usados goniômetros flexíveis na região lateral do joelho e do tornozelo. A colocação do goniômetro do tornozelo é mostrada na Figura 22 (o goniômetro do joelho é mostrado na próxima seção).

Para a geração do balanço, foi usada a sequência de estimulação do Teste Piloto 2. O paciente é mostrado durante a fase de balanço na Figura 23. Na figura também pode-se ver a localização dos eletrodos usados na estimulação do nervo peroneal comum (a localização dos eletrodos femorais é mostrada mais claramente na próxima seção).

Foram usados dois interruptores manuais. Um para a ativação da fase de balanço, e outro para induzir o aprendizado 'on-line'. A técnica de aprendizado 'off-line' é a mesma descrita no Teste Piloto 1. A diferença é que neste caso a variação é na LP, o paciente está em pé, e são usados dois goniômetros. Para o treinamento 'off-line' foram gravados quinze pares entrada-saída obtidos numa sessão separada. A tolerância usada foi 0.02, equivalente a um erro máximo de $40\mu\text{s}$ para a estimulação na faixa de $40\mu\text{s}$ a 1.0 ms.



Figura 22 - Localização do goniômetro flexível no tornozelo.

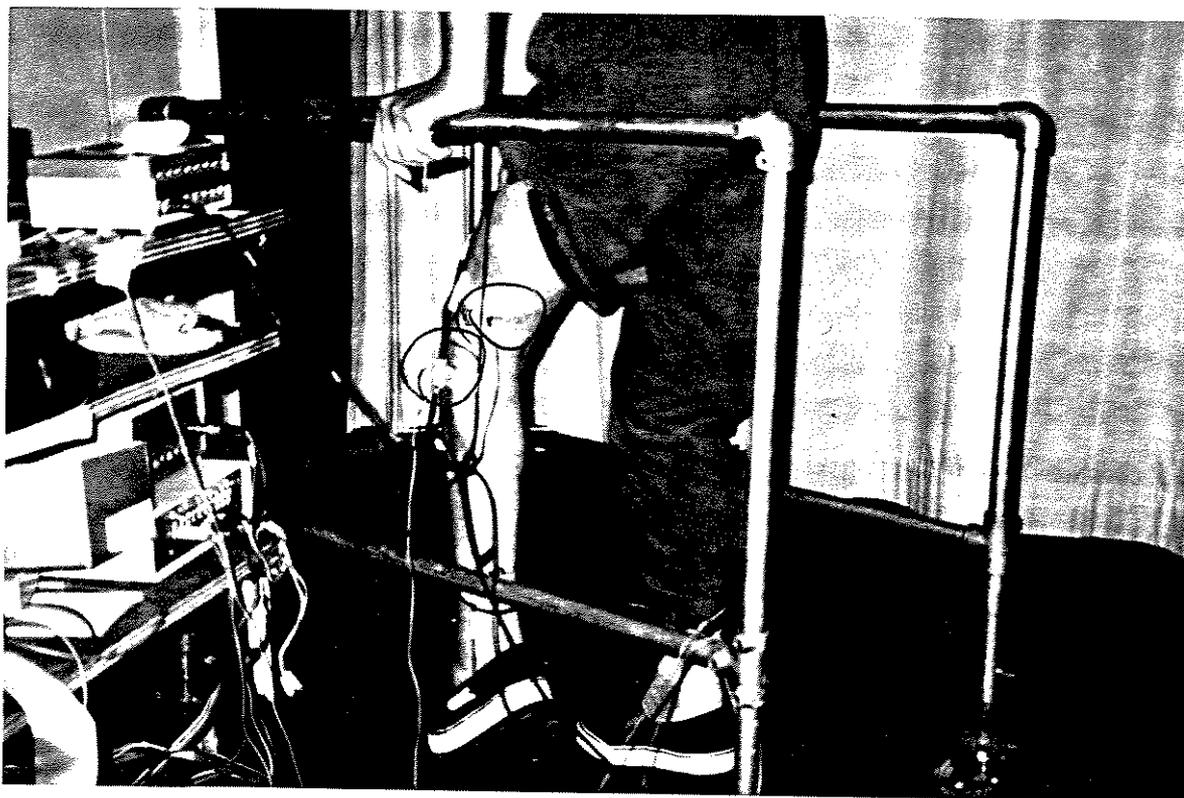


Figura 23 - Execução da fase de balanço via EENM controlada por rede neural em paciente com lesão incompleta de nível C6. A figura mostra como o paciente mantém-se em pé. Também podem ser vistos os eletrodos para estimulação do nervo peroneal comum (marcados com um círculo).

Para reduzir a fadiga muscular, foi eliminada a estimulação femoral durante a fase de apoio. Isto só foi possível por que o paciente pôde manter-se em pé apoiando-se na perna direita e nas barras paralelas.

Foi feito um programa em linguagem Turbo Pascal para todo o sistema. O programa, denominado NNW4 (Neural NetWalk 4.0) pode ser requisitado por correio eletrônico (francisc@deb.fee.unicamp.br).

4.4.1.1 Aprendizado 'On-line'

O sistema incluiu duas formas de aprendizado "on-line": reforço positivo (R) e reforço negativo, ou punição (P).

Punição foi aplicada à rede neural (previamente treinada 'off-line') sempre que o movimento observado foi considerado inadequado pelo operador. P consistiu em reduzir em 10% a magnitude de vários pesos sinápticos escolhidos aleatoriamente (10% dos pesos entre as camadas de entrada e escondida, e 10% dos pesos entre as camadas escondida e de saída). Ao modificar os pesos sinápticos desta maneira, a rede neural teoricamente não gera mais a saída errada para um vetor de entrada similar ao que a gerou. Ou seja, a rede é 'punida' por responder de maneira errada a uma dada entrada. Além disso, os pesos sinápticos têm que ser escolhidos aleatoriamente porque nenhum peso em particular é o responsável pela má resposta da rede (uma idéia fundamental na filosofia conexionista). O valor de 10% é escolhido para afetar alguns dos pesos sinápticos somente um pouco. Uma mudança mais drástica dos pesos sinápticos faz com que a rede 'esqueça' aquilo que aprendeu 'off-line'. De qualquer forma, tanto a técnica de punição como a de reforço positivo usadas neste trabalho estão sujeitas a questionamento.

Reforço positivo é aplicado da seguinte maneira. Quando um bom ciclo é observado, os ângulos gerados são usados como vetor de entrada para o treinamento da rede, com um vetor de saída meta equivalente a não modificar a LP que gerou este movimento, ou seja, para dois canais de estimulação, o vetor de saída meta é (0.5, 0.5). Este par entrada-saída é então apresentado à rede para que ela o aprenda durante a fase de apoio. O processo dura por tantas fases de apoio quanto forem necessárias até a rede neural atingir a tolerância de 0.02. Ou, o processo pode ser interrompido ao ser aplicada punição novamente.

O processo de aprendizado 'on-line' é desencadeado mediante pressão de um interruptor dedicado a esta função. Se este interruptor é pressionado, na próxima fase de apoio o programa controlador espera até que o operador digite um índice. Se este índice é um número positivo, o índice transforma-se na taxa de aprendizado e o processo de reforço positivo é iniciado (com a taxa de aprendizado digitada). Se o índice é negativo, punição é aplicada uma vez somente. Um índice igual a zero representa apenas uma pausa no

programa. A fase de balanço produzida logo após o acionamento do interruptor já inclui correções resultantes das modificações sinápticas.

4.4.2 Sistema 2 (S2)

No sistema S2, os eletrogoniômetros foram colocados no joelho e quadril esquerdos (Figure 24). O goniômetro do tornozelo foi transferido para o quadril por que em S1 observou-se que às vezes, no reflexo de retirada, a dorsiflexão e a flexão de joelho eram adequadas, mas a flexão de quadril não era suficiente para permitir fácil liberação do pé. Portanto, optou-se por monitorar o quadril durante a retirada. Melhor ainda seria monitorar os ângulos das três articulações, mas havia somente dois goniômetros disponíveis em perfeito estado.



Figura 24 - Localização dos goniômetros de quadril e joelho. Também pode-se ver a localização dos eletrodos femorais.

Também foi modificada a sequência de estimulação com respeito a S1. Em S2, a fase de balanço foi reduzida para 3s, para retardar o aparecimento da fadiga. Uma duração menor que 3s dificulta o movimento do paciente que leva algum tempo para fazer a movimentação do tronco para poder dar o passo. Na primeira metade do balanço, foi aplicada estimulação peroneal, como em S1. Mas, na conclusão do balanço, foi removida a estimulação peroneal, para retardar a fadiga muscular e também a acomodação do reflexo de retirada. Ao ativar juntos os canais femoral e peroneal na conclusão do balanço, além de prolongar o estímulo no nervo peroneal comum, é necessário uma LP maior no nervo femoral para superar a flexão de joelho induzida pelo reflexo. Porém a remoção do sinal peroneal trouxe alguns problemas (veja Capítulo 6).

Também foi aumentada a frequência de amostragem para 10 Hz. Isto foi feito para evitar reduzir o tamanho do vetor de entrada para a rede neural ao reduzir a duração do ciclo para 3s (8Hz seriam suficientes, mas 10Hz foram escolhidos por conveniência na programação). Isto resultou num vetor de entrada com 30 elementos.

O treinamento 'on-line' e 'off-line' da rede neural seguiu as técnicas descritas em S1, com uma diferença importante. Em S2, tentou-se estabelecer critérios mais rígidos para a aquisição de exemplos para o treinamento. Para S2, foram usadas todas as combinações possíveis entre as duas colunas mostradas na Tabela 3. Isto foi feito para treinar a rede com um conjunto de dados supostamente representativo de todas as possibilidades.

<u>CANAL FEMORAL</u>	<u>CANAL PERONEAL</u>
= 0	= 0
= If	= Ip
< If	< Ip
<< If	<< Ip
> If	> Ip
>> If	>> Ip

Tabela 3 - Padrões de estimulação usados durante a aquisição de exemplos para treinamento. Foram usadas todas as combinações possíveis entre as duas colunas, num total de 36 ciclos de exemplo. If = LP ideal observada para o canal femoral durante a sessão. Ip = LP ideal para o canal peroneal. Os valores exatos usados podem ser vistos no Capítulo 6.

4.4.3 Avaliação do Desempenho

Para a avaliação do desempenho dos sistemas S1 e S2, foi calculado o coeficiente de correlação de Pearson (Capítulo 3) entre os movimentos produzidos e o melhor ciclo produzido durante a sessão de testes. Em quase todas as sessões de teste, pelo menos um ciclo bom foi produzido (a julgar pelo grau de semelhança entre o passo gerado e um passo normal) e pôde ser usado como referência. Em algumas das sessões de teste, não foi observado qualquer ciclo aceitável. Isto ocorreu por que o paciente não havia tomado o medicamento antiespasmódico (que ele regularmente toma) por duas ou mais semanas, devido à colaboração do paciente em outro projeto. Os dados referentes a estas sessões foram descartados.

Os coeficientes de correlação encontraram-se na faixa (0.0, 0.99). Então, para aumentar a diferença entre o desempenho dos vários esquemas testados, os coeficientes foram elevados ao quadrado. Este valor (cr^2) foi usado como fator de comparação.

As sessões de teste foram organizadas de acordo com a seguinte sequência (P = punição; R = reforço positivo):

DIA 1: São obtidos os arquivos de exemplo para treinamento da rede. A rede neural é treinada 'off-line'.

Dia 2:

1. Obtenção de um ciclo bom para referência (ajustes manuais).
2. Teste da rede treinada 'off-line' (**Rede 1**) seguindo o Teste Sem Adaptação (TSA) (Figura 25) ao iniciar-se a sessão.
3. TSA com a Rede 1 após 40 ciclos de balanço.

DIA 3: A seguinte sequência é seguida:

1. Obtenção de um ciclo bom para referência (ajustes manuais).

2. Controle com P com a Rede 1, gerando a **Rede 2**.
3. TSA para a Rede 2.

Dia 4:

1. Obtenção de um ciclo bom para referência (ajustes manuais).
2. Controle com R com a Rede 1, gerando a **Rede 3**.
3. TSA com a Rede 3.

Dia 5 :

1. Obtenção de um ciclo bom para referência (ajustes manuais).
2. Controle com P e R, com a Rede 1, gerando a **Rede 4**.
3. TSA com a Rede 4.

Durante os testes de **S1**, foram necessárias seis semanas até que todos os testes fossem executados com sucesso. Já nos testes de **S2**, a sequência acima foi concluída em duas semanas. Um dos problemas encontrados foi o aparecimento de fadiga ou habituação do reflexo antes da conclusão do teste. Por esta razão o número de ciclos de teste teve que ser reduzido a um mínimo.

Em todos os testes experimentais, valores de crc^2 mais próximos de 1.0 denotam um melhor desempenho.

No TSA abaixo, as LPs de ciclos não marcados com flechas são definidas pela rede neural controladora baseado no ciclo prévio.

Nos testes referentes ao controle durante P, R, e P+R, foram calculados os valores de crc^2 apenas para os ciclos imediatamente após a aplicação do aprendizado 'on-line'.

TESTE SEM ADAPTAÇÃO
(06-16-95)

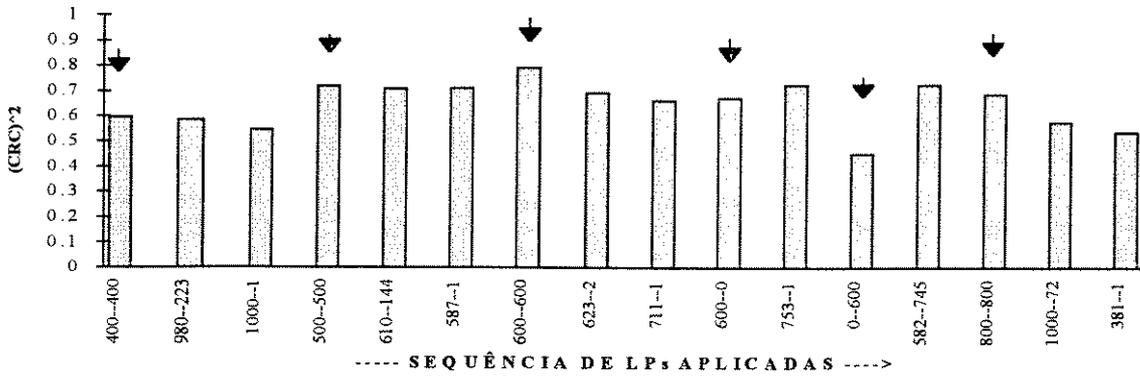


Figura 25 - Teste Sem Adaptação sináptica (TSA). É mostrada a sequência usada num dos testes. As flechas denotam ciclos antes dos quais o operador ajustou as larguras de pulso. Eixo horizontal: LP aplicada aos canais femoral e peroneal ('fem. -- per.', em μs). Por exemplo, '980--223' denota uma LP de 980 μs aplicada no nervo femoral e 223 μs aplicados no canal peroneal. Na comparação entre os sistemas, foram considerados os crc^2 somente dos ciclos não marcados por uma flecha. Os valores exatos usados nos ciclos marcados variam de dia para dia, mas a diferença entre as LP nestes ciclos e a LP do ciclo ideal obtido no início da sessão é a mesma. No exemplo ilustrado, o ciclo ideal inicial havia sido obtido com 500 μs -- 500 μs .

CAPÍTULO 5

RESULTADOS: SISTEMA TEÓRICO

Foram feitos dois testes com o modelo neural descrito no Capítulo 3. Primeiro, com a rede neural treinada com 2/3 dos dados normais disponíveis, foi calculado a MQE para as fases de apoio (MQE_A) e de balanço (MQE_B), e para o ciclo completo (MQE_{CC}). Para o cálculo da MQE, foram usados como entrada os dados referentes aos restantes 1/3 dos dados (a porção não usada no treinamento). A resposta da rede foi comparada às atividades musculares reais. No segundo teste, todo o conjunto de dados normais foi usado para o treinamento. Então, foram usados dados patológicos para a entrada das redes, sendo a resposta das redes comparada às saídas patológicas reais. Para este teste foram calculados os valores de MQE e coeficientes de correlação entre os dados previstos e os reais.

5.1 TESTE COM 1/3 DOS DADOS NORMAIS (TESTE 1)

Tanto neste teste como na simulação patológica, os resultados referentes à Rede 1 (veja Capítulo 3) serão mostrados em detalhe. Os resultados para as outras redes serão listados de forma resumida.

Então, para a Rede 1, são mostradas as saídas previstas e as reais na Tabela 4 abaixo.

<i>Entradas</i>	<i>Quadril</i>	<i>Joelho</i>	<i>Tornozelo</i>	<i>FR</i>	<i>Quadro</i>	
	0.7074	0.3717	0.5592	0.7422	3	
	0.4784	0.3233	0.7434	0.6167	6	
	0.2852	0.2542	0.7965	0.6983	9	
	0.2072	0.4058	0.5866	0.5189	12	
	0.5744	0.7965	0.2961	0.2000	15	
	0.8039	0.5377	0.6058	0.2000	18	
<i>MÚSCULO</i>						
<i>Saídas Previstas</i>	<i>1</i>	<i>2</i>	<i>3</i>	<i>4</i>	<i>5</i>	<i>Quadro</i>
	0.7160	0.7240	0.5460	0.7360	0.3470	3
	0.8230	0.5740	0.8150	0.6810	0.4470	6
	0.4660	0.3650	0.6020	0.2580	0.2590	9
	0.4290	0.3600	0.4630	0.2730	0.2800	12
	0.3260	0.3020	0.2900	0.2150	0.4790	15
	0.2880	0.2670	0.2850	0.2100	0.5670	18
<i>Saídas Reais</i>						<i>Quadro</i>
	0.6140	0.4762	0.7541	0.4261	0.3833	3
	0.3653	0.3077	0.3434	0.2125	0.2785	6
	0.2860	0.2617	0.3176	0.2567	0.8039	9
	0.2973	0.2813	0.3672	0.2647	0.3691	12
	0.4007	0.3105	0.3061	0.4914	0.2514	15
	0.2827	0.6460	0.2549	0.3953	0.2233	18

Tabela 4 - Saídas previstas e reais para a Rede 1 treinada com 2/3 dos dados normais disponíveis e testada com os 1/3 restantes. O número do quadro deve ser multiplicado por 5% para obter a porcentagem correspondente do ciclo da marcha (veja figuras de dados para treinamento e definição dos termos no Capítulo 3).

Com os números acima foram obtidos os resultados mostrados na Tabela 5 abaixo.

Os valores de MEQ à direita constituem a média dos cinco músculos para cada quadro.

MQE_A é então calculado segundo a média aritmética dos valores de MQE para os quadros 3,

6, 9, 12. MQE_B corresponde à média para os quadros 15 e 18, e MQE_C à média de todos os

quadros. Na Tabela 6, encontram-se resumidos os resultados referentes a todas as redes

neurais.

<i>Quadro</i>	$(\text{Previsto-Real})^2$					<i>MOE</i>
	MÚSCULO					
	1	2	3	4	5	
3 (apoio)	0.0104	0.0614	0.0433	0.0960	0.0013	0.0425
6 (apoio)	0.2095	0.0709	0.2224	0.2195	0.0284	0.1501
9 (apoio)	0.0324	0.0107	0.0809	0.0000	0.2969	0.0842
12 (apoio)	0.0173	0.0062	0.0092	0.0001	0.0079	0.0081
15 (balanço)	0.0056	0.0001	0.0003	0.0764	0.0518	0.0268
18 (balanço)	0.0000	0.1436	0.0009	0.0343	0.1181	0.0594
<i>MOE_{CC}</i> =		0.0619				
<i>MOE_A</i> =		0.0712				
<i>MOE_B</i> =		0.0431				

Tabela 5 - Cálculos feitos com os dados da tabela 4. São obtidos os valores de MOE_A , MOE_B , e MOE_{CC} para a Rede 1. Estes são os valores usados para comparação das redes no teste com 1/3 dos dados normais.

<i>REDE</i>	<i>MOE_{CC}</i>	<i>MOE_A</i>	<i>MOE_B</i>
1	0.0619	0.0712	0.0431
2	0.0610	0.0774	0.0281
3	0.0626	0.0806	0.0266
4	0.0557	0.0644	0.0384
5	--	0.0646	--
6	--	--	0.0152
7	--	0.0664	--
8	--	--	0.0126
9	--	0.0758	--
10	--	--	0.0155
11	--	0.0801	--
12	--	--	0.0136
13	--	0.0651	--
14	--	--	0.0147
15	--	0.0690	--
16	--	--	0.0154
17	0.0602	0.0789	0.0228
18	0.0643	0.0829	0.0271
19	0.0598	0.0725	0.0345
20	0.0600	0.0679	0.0443
21	0.0607	0.0786	0.0247

Tabela 6 - Resultados do Teste 1. Valores de MOE_A , MOE_B , e MOE_{CC} obtidos para todas as redes neste teste com 1/3 dos dados normais. Os valores ausentes indicam uma rede não treinada para controle na fase em questão.

5.2 SIMULAÇÕES PATOLÓGICAS (TESTE 2)

Para as simulações patológicas, foram usada as entradas listadas na Tabela 7. Com base nestes valores, a Rede 1, treinada com o conjunto de dados normais, gerou as previsões para as atividades musculares mostradas na Tabela 8. Mais abaixo, a Tabela 9 mostra os valores reais de saída para a situação patológica.

ENTRADAS PATOLÓGICAS

<i>Quadro</i>	<i>Quadril</i>	<i>Joelho</i>	<i>Tornozelo</i>	<i>FR</i>
1	0.69765	0.37813	0.29776	0.20000
2	0.67647	0.41953	0.39163	0.62899
3	0.62706	0.42813	0.48755	0.72391
4	0.55529	0.37500	0.52837	0.79928
5	0.46235	0.29688	0.49980	0.61304
6	0.38471	0.23281	0.52020	0.50217
7	0.29647	0.20078	0.57939	0.52609
8	0.22706	0.20234	0.64469	0.62536
9	0.20824	0.25625	0.79980	0.71594
10	0.26118	0.38516	0.72837	0.61087
11	0.38824	0.56797	0.37327	0.26159
12	0.52941	0.72578	0.20184	0.20000
13	0.65765	0.80078	0.22837	0.20000
14	0.76235	0.77656	0.36510	0.20000
15	0.80235	0.63281	0.56102	0.20000
16	0.76353	0.40703	0.55898	0.20000
17	0.72353	0.35781	0.43653	0.20000
18	0.69294	0.42344	0.39571	0.20000
19	0.66353	0.45859	0.55490	0.20000
20	0.59765	0.41875	0.61816	0.20000

Tabela 7 - Dados patológicos normalizados usados na entrada das redes neurais treinadas somente com dados normais.

PREVISÃO DA REDE					
MÚSCULO					
	<i>1</i>	<i>2</i>	<i>3</i>	<i>4</i>	<i>5</i>
Quadro					
<i>1</i>	0.8279	0.6003	0.7118	0.6914	0.4569
<i>2</i>	0.5569	0.5270	0.7483	0.4749	0.3888
<i>3</i>	0.4158	0.4360	0.6409	0.3545	0.3021
<i>4</i>	0.3330	0.4072	0.5885	0.3267	0.2893
<i>5</i>	0.3856	0.3712	0.5367	0.3484	0.3420
<i>6</i>	0.5064	0.2605	0.5320	0.5148	0.5396
<i>7</i>	0.6010	0.1498	0.5643	0.7216	0.7930
<i>8</i>	0.5784	0.1273	0.5878	0.7295	0.8679
<i>9</i>	0.2612	0.2128	0.3525	0.2712	0.8348
<i>10</i>	0.1771	0.3697	0.2355	0.1138	0.3656
<i>11</i>	0.3777	0.3523	0.3845	0.3007	0.2585
<i>12</i>	0.4680	0.3548	0.3811	0.4925	0.3339
<i>13</i>	0.4876	0.3159	0.3319	0.5559	0.3358
<i>14</i>	0.4185	0.3149	0.2718	0.5241	0.2898
<i>15</i>	0.2935	0.5025	0.2238	0.4203	0.1977
<i>16</i>	0.4343	0.6415	0.3521	0.4753	0.2179
<i>17</i>	0.7236	0.5986	0.5896	0.6240	0.3397
<i>18</i>	0.7396	0.5339	0.5615	0.6150	0.3478
<i>19</i>	0.5111	0.5594	0.3262	0.4475	0.2379
<i>20</i>	0.4455	0.6375	0.2501	0.3441	0.2343

Tabela 8 - Valores de atividade muscular normalizada previstos pela Rede 1 treinada com todo o conjunto de dados normais. Na entrada da rede foram usados os valores listados na Tabela 7 acima.

Usando-se os dados das Tabelas 8 e 9, são calculados os valores de MQE_A , MQE_B , MQE_{CC} , crc_A , crc_B , e crc_{CC} para a Rede 1, de acordo com as equações do Capítulo 3. Estes valores são mostrados na Tabela 10.

Abaixo, nas Figuras 26 a 30, são mostradas as atividades musculares previstas e reais para os cinco músculos simulados. São mostradas somente as curvas referentes à Rede 1. Através destas figuras pode-se fazer uma análise qualitativa das previsões da Rede 1.

ATIVIDADE REAL					
MÚSCULO					
	<i>1</i>	<i>2</i>	<i>3</i>	<i>4</i>	<i>5</i>
Quadro					
<i>1</i>	0.6191	0.3754	0.6007	0.5800	0.8084
<i>2</i>	0.2736	0.3754	0.4993	0.5600	0.4792
<i>3</i>	0.2391	0.3754	0.5500	0.6000	0.4044
<i>4</i>	0.2045	0.3851	0.6260	0.5200	0.3895
<i>5</i>	0.2045	0.2779	0.8033	0.4600	0.4194
<i>6</i>	0.2045	0.2974	0.6260	0.3400	0.3146
<i>7</i>	0.2045	0.3072	0.2460	0.2000	0.3745
<i>8</i>	0.2218	0.3462	0.2207	0.2400	0.2847
<i>9</i>	0.2045	0.2585	0.1953	0.7200	0.2249
<i>10</i>	0.2045	0.2195	0.1953	0.8000	0.2249
<i>11</i>	0.2045	0.2097	0.3727	0.6600	0.2249
<i>12</i>	0.2045	0.2487	0.7273	0.5200	0.2249
<i>13</i>	0.3427	0.5800	0.6007	0.5600	0.2099
<i>14</i>	0.2736	0.8041	0.4487	0.5400	0.2847
<i>15</i>	0.3600	0.4923	0.4740	0.5400	0.4642
<i>16</i>	0.8091	0.2974	0.7527	0.5400	0.4942
<i>17</i>	0.7054	0.3267	0.7527	0.3000	0.4942
<i>18</i>	0.2736	0.3072	0.4993	0.2800	0.5091
<i>19</i>	0.2218	0.2877	0.5247	0.2200	0.4194
<i>20</i>	0.7054	0.4046	0.7273	0.5800	0.5690

Tabela 9 - Atividades musculares reais (normalizadas) para o caso patológico (descrito no Capítulo 3).

RESULTADOS PARCIAIS					
MÚSCULO					
	<i>1</i>	<i>2</i>	<i>3</i>	<i>4</i>	<i>5</i>
<i>crc_{CC}</i>	0.3537	-0.0069	0.1173	-0.7269	-0.2339
<i>crc_A</i>	0.7134	0.3529	0.3629	-0.8018	-0.1296
<i>crc_B</i>	0.0334	-0.8573	0.2609	-0.4638	-0.3317
<i>MQE_{CC}</i>	0.0619	0.0449	0.0585	0.0909	0.0743
<i>MQE_A</i>	0.0569	0.0181	0.0455	0.1228	0.0941
<i>MQE_B</i>	0.0695	0.0851	0.0780	0.0429	0.0448
RESULTADOS GERAIS					
<i>crc_{CC}</i>	<i>crc_A</i>	<i>crc_B</i>	<i>MQE_{CC}</i>	<i>MQE_A</i>	<i>MQE_B</i>
-0.0993	0.0996	-0.2717	0.0661	0.0675	0.0641

Tabela 10 - Resultados quantitativos obtidos para a Rede 1.

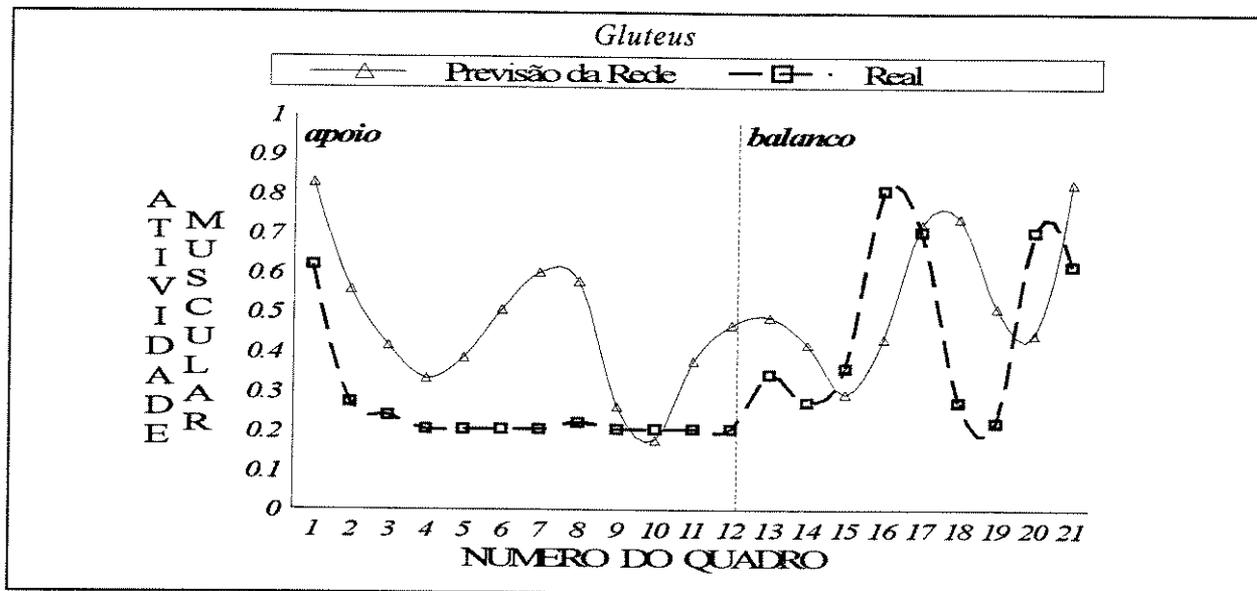


Figura 26 - Nível de atividade muscular gluteal real e previsto pela Rede 1 para a simulação patológica. A fase de apoio termina aos 60% do ciclo de marcha, ou seja, no quadro de número 12.

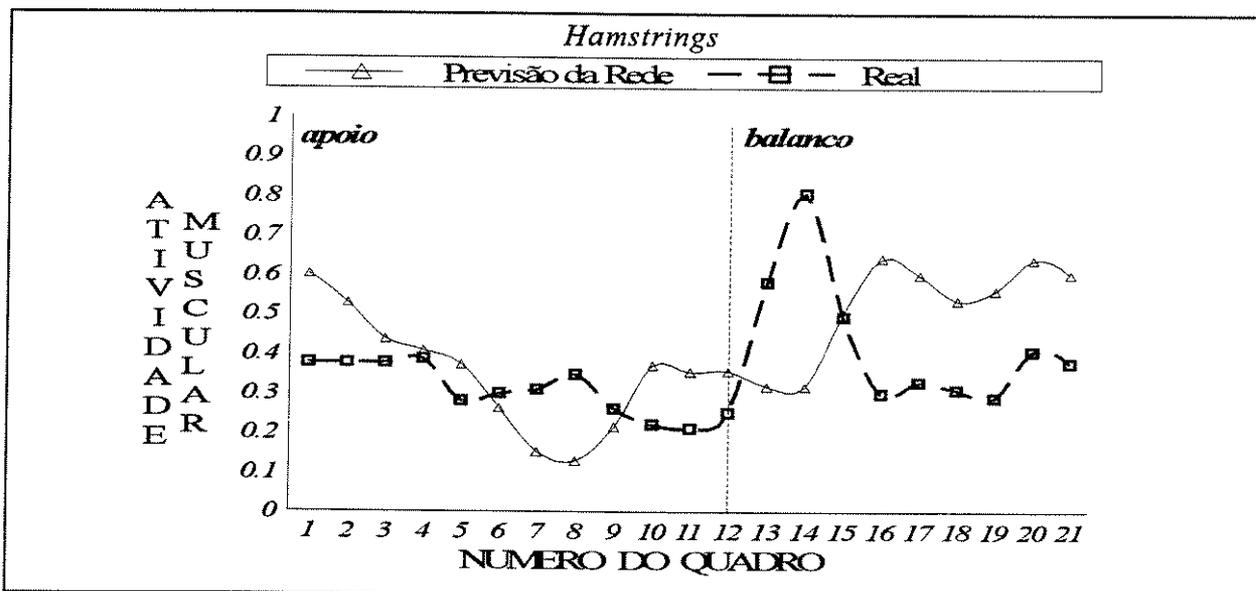


Figura 27 - Atividade do grupo Hamstrings para a simulação patológica, valores previstos pela Rede 1 e valores reais.

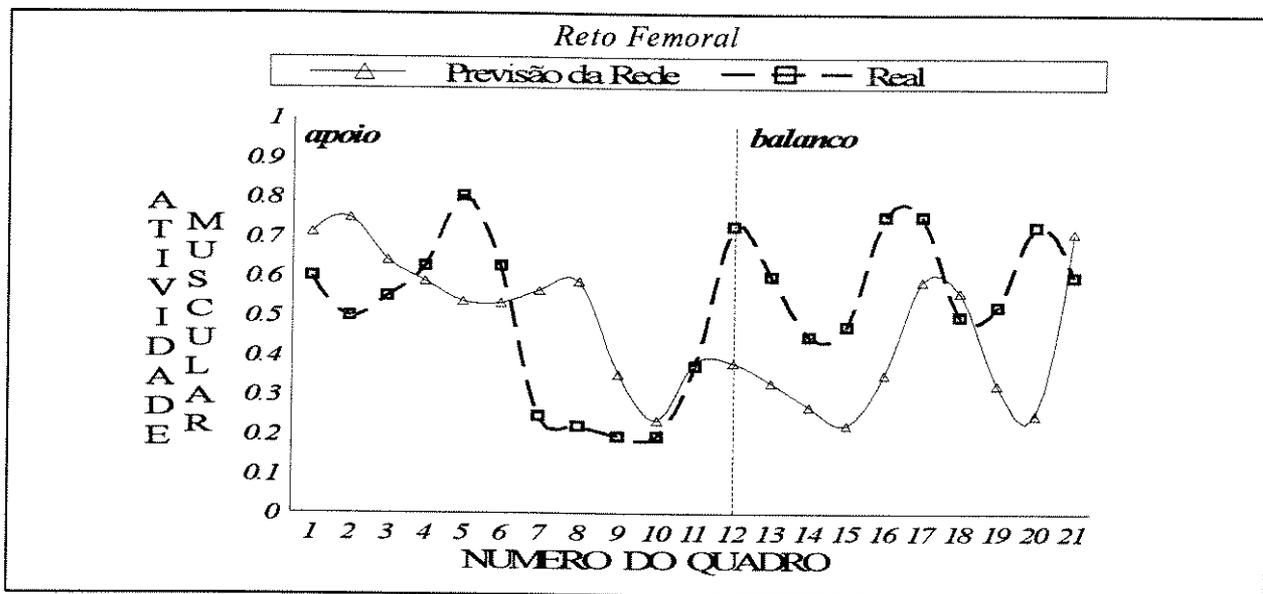


Figura 28 - Atividade do Reto Femoral para a simulação patológica, valores previstos pela Rede 1 e valores reais.

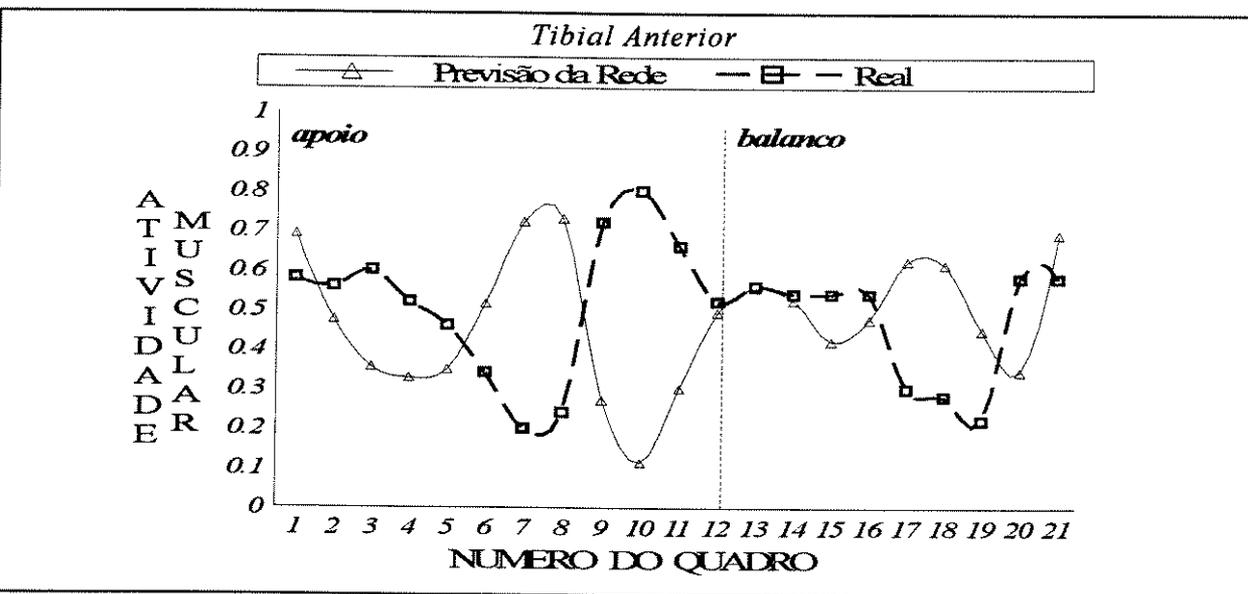


Figura 29 - Atividade do Tibial Anterior para a simulação patológica, valores previstos pela Rede 1 e valores reais.

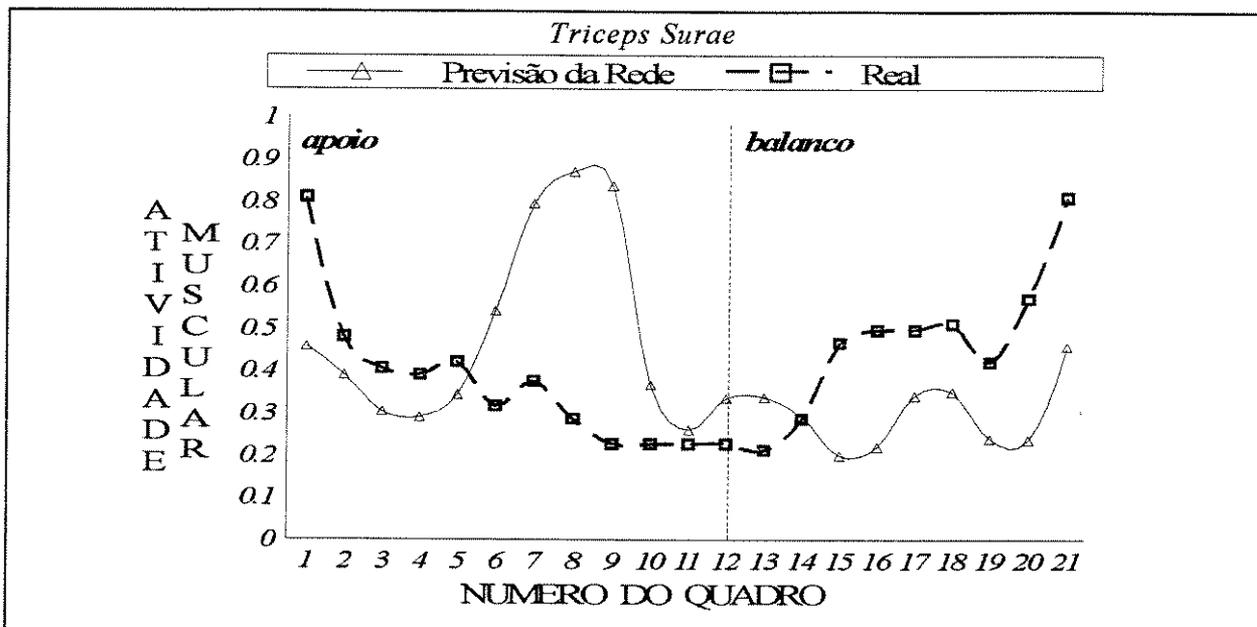


Figura 30 - Atividade do Triceps Surae para a simulação patológica, valores previstos pela Rede 1 e valores reais.

REDE	crc_{cc}	crc_A	crc_B	MQE_{cc}	MQE_A	MQE_B
1	-0.0993	0.0996	-0.2717	0.0661	0.0675	0.0641
2	0.1618	0.0704	0.2712	0.0653	0.0712	0.0565
3	-0.0722	0.0711	-0.2135	0.2067	0.0545	0.0475
4	0.0333	0.4170	-0.2054	0.0546	0.0505	0.0608
5	--	0.2328	--	--	0.0882	--
6	--	--	-0.0284	--	--	0.0700
7	--	0.1078	--	--	0.1409	--
8	--	--	0.2081	--	--	0.0751
9	--	0.3957	--	--	0.0661	--
10	--	--	-0.3567	--	--	0.1170
11	--	0.1948	--	--	0.0680	--
12	--	--	-0.0104	--	--	0.0667
13	--	-0.2355	--	--	0.0915	--
14	--	--	0.0866	--	--	0.0785
15	--	0.0963	--	--	0.1076	--
16	--	--	0.0248	--	--	0.0823
17	-0.0429	0.2298	-0.2250	0.0602	0.0553	0.0675
18	-0.1124	-0.0076	-0.2514	0.0493	0.0413	0.0612
19	-0.0446	-0.0154	-0.0335	0.0421	0.0418	0.0425
20	-0.1534	0.2841	-0.1734	0.0641	0.0571	0.0746
21	-0.1897	0.1371	-0.1570	0.0806	0.0785	0.0836

Tabela 11 - Resultados gerais obtidos na simulação patológica (TESTE 2).

5.3 ANÁLISE DOS RESULTADOS

Na Figura 31, vemos os valores de MQE para o Teste 1. Considerando-se que enquanto maior o valor de MQE, pior é o desempenho da rede, as Redes 6, 8, 10, 12, 14, e 16 têm melhor desempenho, baseado neste teste. Em geral, desta figura, pode-se concluir que o desempenho de todas as redes com controle na fase de balanço é melhor que o das redes para a fase de apoio. Inclusive, MQE_B para as redes com controle para todo o ciclo da marcha é consistentemente menor que MQE_A e MQE_{CC} . O mesmo pode ser observado nos valores de MQE para o Teste 2, ainda que neste caso a diferença entre os valores para a fase de balanço e para a fase de apoio não é tão pronunciada. Além disso, MQE para a Rede 10 neste caso é maior que para a Rede 9 (estas redes têm a mesma estrutura, veja a Tabela 2 Capítulo 3, mas a Rede 9 exerce controle na fase de apoio, enquanto a Rede 10 trabalha na fase de balanço).

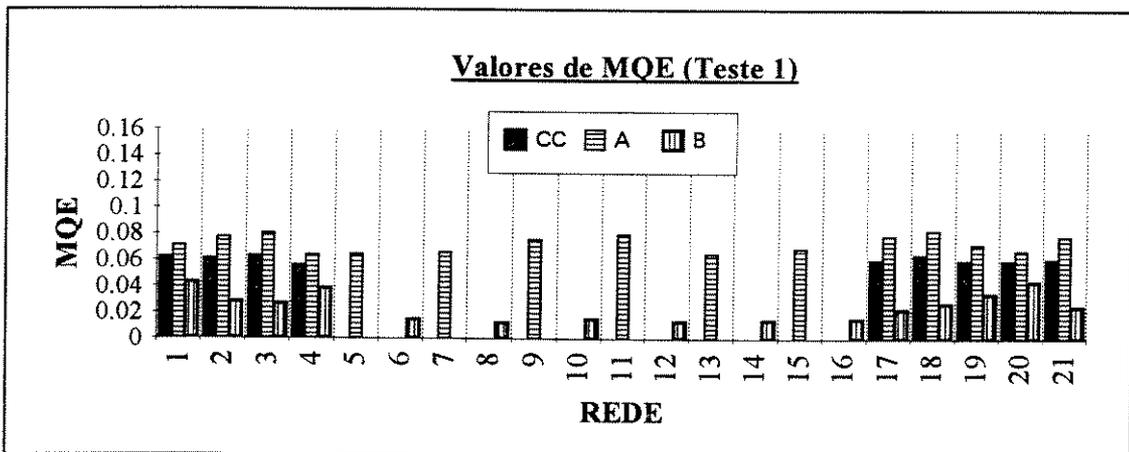


Figura 31 - Valores de MQE para o Teste 1. As linhas pontilhadas separam uma rede da outra. Os valores foram extraídos da Tabela 6 acima.

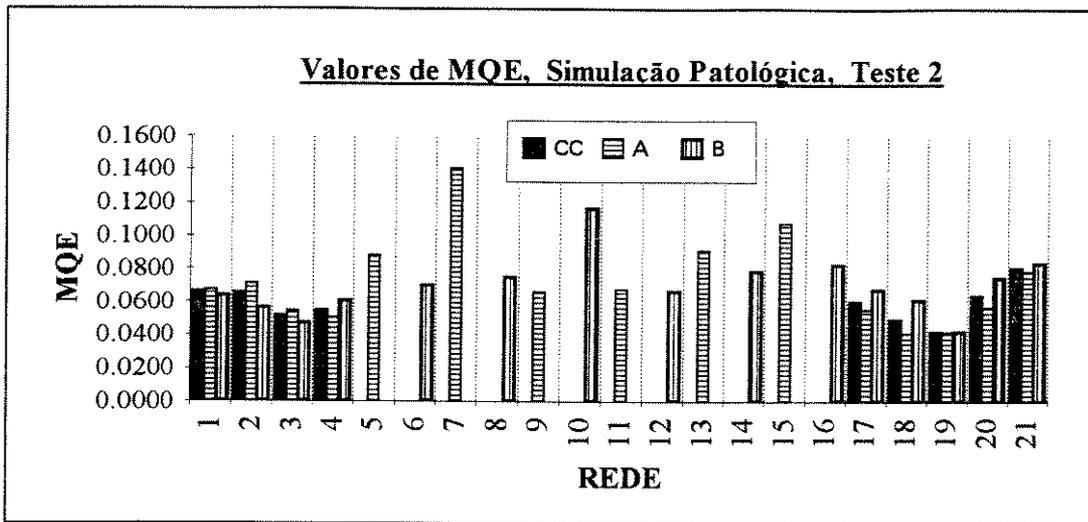


Figura 32 - Valores de MQE para o Teste 2. Os valores foram extraídos da Tabela 11, acima.

Porém, os valores de crc para o Teste 2, mostrados na Figura 33, contradizem as conclusões obtidas acima com os testes baseados na MQE. Ao observar a Figura 33, deve-se ter em mente que enquanto mais próximo o valor do crc estiver de $\text{crc} = +1$, melhor é o desempenho da rede.

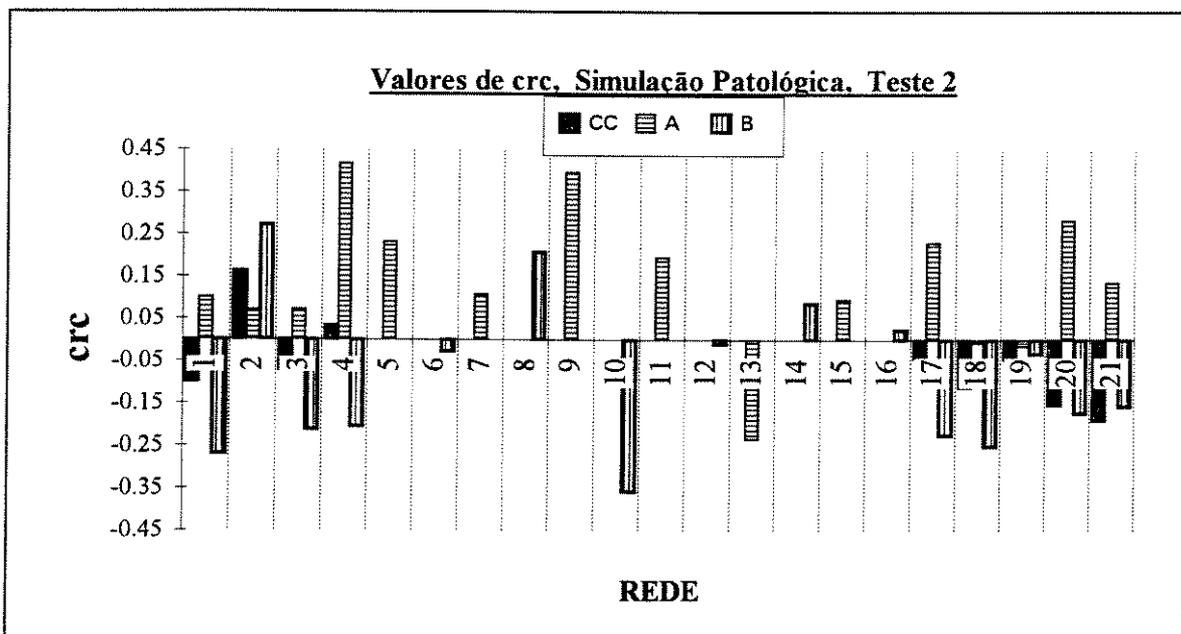


Figura 33 - Valores de crc para o Teste 2.

De acordo com os valores na Figura 33 acima, os melhores desempenhos foram obtidos durante a fase de **apoio**, A (as exceções são as Redes 2, 8, 13 e 14). As possíveis razões para a diferença entre as conclusões entre testes baseados em MQE e crc serão discutidas no Capítulo 7. Entretanto, por agora, os valores serão acumulados para obter um único índice, a ser chamado **Índice de Desempenho**, para cada rede. Para obter este índice, leva-se em conta que enquanto maior o valor de MQE, pior é o desempenho da rede, e que os valores de MQE são sempre maiores que zero. Também considera-se que enquanto maior o valor de crc, melhor é o desempenho da rede. Então,

$$\text{Índice de Desempenho} = \text{ID} = \text{crc} - \text{MQE}_{(\text{Teste 1})} - \text{MQE}_{(\text{Teste 2})}.$$

Enquanto maior é o valor do índice, melhor é o desempenho da rede. Dada a magnitude dos valores de MQE, o valor do índice depende predominantemente na magnitude de crc.

De acordo com o Índice de Desempenho (Figura 34), a Rede 9 apresentou o melhor controle. As Redes 4, 17, e 20 tiveram bom desempenho na fase de apoio, e, para a fase de balanço, as redes 2 e 8 geraram bons resultados.

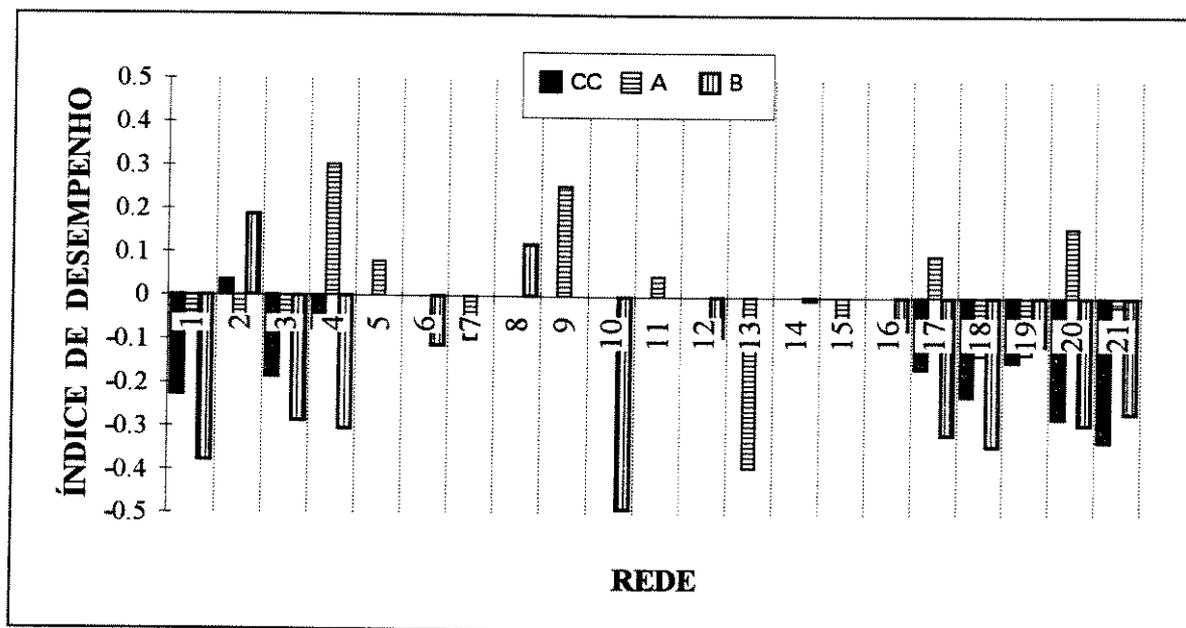


Figura 34 - Índice de Desempenho (ID) cumulativo para todas as redes.

De modo geral, todas as redes treinadas para controle durante todo o ciclo da marcha tiveram um desempenho ruim. Dentre elas, a Rede 2 parece ser mais apropriada que as outras.

Para uma análise mais objetiva, têm que ser estudados os seguintes aspectos já mencionados no Capítulo 3:

1. Memória das entradas passadas,
2. Usar a última saída como entrada,
3. Recursão no algoritmo de aprendizado,
4. Conectividade seletiva entre as camadas escondida e de saída,
5. Usar as derivadas dos sinais de entrada e de saída, e
6. Redes separadas para as fases de apoio e balanço.

Cada um dos fatores será analisado, a seguir. A Rede 1 é tida como referência em toda esta análise (veja a Tabela 2, Capítulo 3, para uma listagem das características de cada rede).

Memória de Entradas Passadas

A Rede 3 difere da Rede 1 somente no que se refere a incluir entradas passadas no vetor de entrada atual. Uma comparação entre os valores de ID para estas redes (Figura 34, acima), acusa um desempenho discretamente melhor para a Rede 3, especialmente durante a fase de balanço.

Usar a Saída como Entrada

A Rede 2 inclui a última saída no vetor de entrada atual. Segundo os valores de ID, isto melhora o desempenho da rede de forma considerável, especialmente na fase de balanço.

Recursão no Aprendizado

A Rede 4 tem recursão nas equações de aprendizado. Seu desempenho é melhor que o da Rede 1, especialmente na fase de apoio. O desempenho geral desta rede (ID_{CC}) é também melhor que o da Rede 3, mas é pior que o rendimento da Rede 2.

Conectividade Seletiva

As redes que incluem seletividade nas conexões entre as camadas escondida e de saída são as Redes 11, 12, 13, 14, e 21. Todas elas também incluem outros fatores que diferem da Rede 1, o que dificulta a análise. De qualquer forma, apesar destas redes terem um desempenho melhor que o da Rede 1 (com a clara exceção da Rede 13), somente a Rede 11 apresenta melhor desempenho que a Rede 2. Além disso, a única diferença entre o par formado pelas Redes 7 e 8, e o par das Redes 13 e 14, é a inclusão de seletividade nas conexões do par 13 e 14. Vê-se, então, que o desempenho das redes claramente cai com conectividade seletiva.

Derivadas do Sinal

As redes 17, 18, e 19 usam derivadas dos sinais de entrada ou de saída. Há uma melhora no desempenho da Rede 17 durante a fase de apoio. Nas demais redes, não é marcante a melhora do desempenho.

Para analisar este fator, é necessário manipular os valores de ID. Na Figura 35, é considerado o ciclo completo da marcha. No caso de redes dedicadas a uma fase (A ou B), é considerada a média do par formado pela redes com a mesma estrutura (por exemplo, as Redes 7 e 8 formam um par). Segundo a Figura 35, a combinação de redes treinadas somente numa das fases é discretamente melhor que as redes treinadas para controle durante todo o ciclo da marcha.

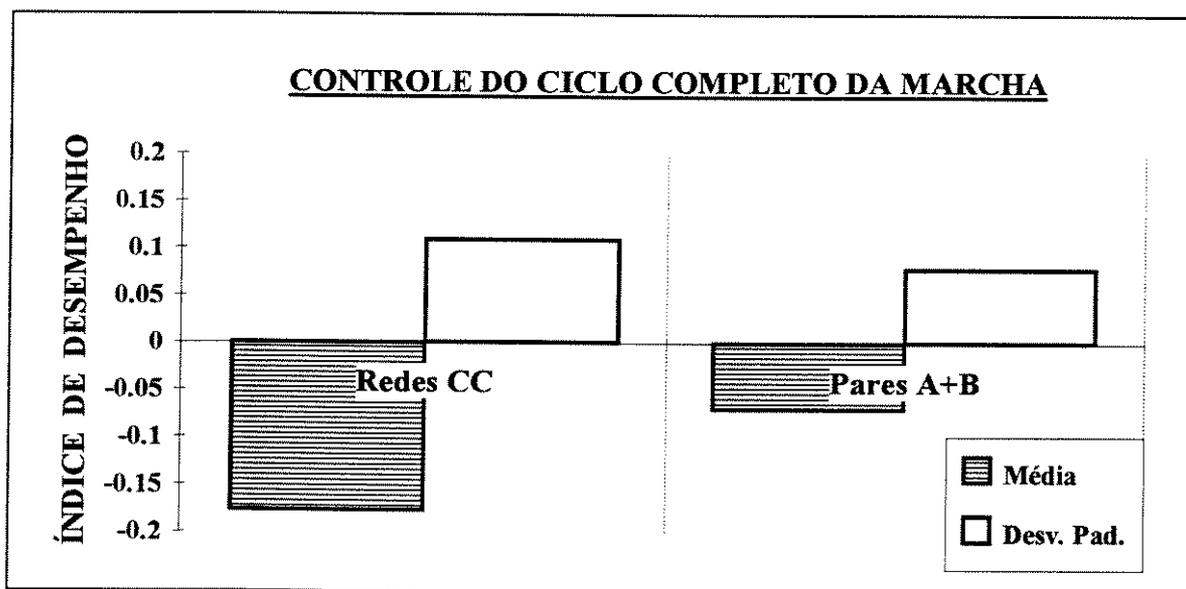


Figura 35 - Desempenho médio das redes treinadas para todo o ciclo *versus* o desempenho médio das redes dedicadas a uma das fases. A+B indica o par formado por duas redes com mesma estrutura mas com controle em fases separadas (uma das redes na fase de apoio, A, e a outra na fase de balanço, B). Desv. Pad. denota o desvio padrão.

CAPÍTULO 6

RESULTADOS: SISTEMA EXPERIMENTAL

Antes da confecção do sistema experimental final, foram feitos três testes piloto para preparar um sistema com um mínimo de problemas. Nos Testes Piloto 1 e 2, a avaliação foi feita através da comparação dos valores previstos pelas redes e os valores ideais obtidos durante a sessão de testes. Para o Teste Piloto 3, não houve qualquer avaliação, já que os dados obtidos indicaram efeitos ambíguos da EENM aplicada.

Para a avaliação do sistema experimental final, foram feitos o Teste Sem Adaptação (Capítulo 4), e testes durante aprendizado 'on-line'. Estes procedimentos foram feitos antes, durante, e depois do treinamento 'on-line' da redes através de punição e reforço positivo. Baseado nos resultados destes testes, foi feito um protótipo para a execução da marcha via rede neural artificial.

6.1 TESTES PILOTO

6.1.1 Teste Piloto 1

6.1.1.1 Problemas Encontrados

Neste teste piloto, observou-se que o controle da estimulação por meio de rede neural durante a fase de apoio não é recomendada, pelo menos por enquanto. Ao usar-se uma só rede para o controle do ciclo completo da marcha, alguns valores de intensidade para a fase de apoio encontraram-se abaixo da faixa útil, o que teria gerado uma queda, não estivesse a

paciente apenas sentada. Foi então removido o controle neural artificial da fase de apoio; para esta fase, passaram a ser usados valores de intensidade preestabelecidos.

6.1.1.2 Desempenho do Sistema

Nos testes com controle neural da fase de apoio, foram obtidos treze (13) ciclos de exemplos para treinamento das redes. A obtenção destes dados durou 1h. A rede neural foi então treinada 'off-line' num computador DX2/50Mhz. Havia sido feita a tentativa de treinar a rede neural no mesmo PC-XT usado para controle, mas o treinamento nesta máquina não deu sinais de convergência mesmo após uma hora de treinamento.

Durante a sessão de testes, também foram gravados 12 arquivos para serem usados apenas como entradas para a rede neural já treinada. Baseado nestes valores, a rede neural foi usada para prever variações na amplitude da tensão aplicada propositadamente errada. Então, os valores corrigidos da estimulação foram comparados aos valores que haviam produzido o melhor movimento durante a sessão de testes (74V no canal femoral, e 74V no canal peroneal). Alguns resultados ilustrativos são mostrados na Tabela 12. A tabela também inclui os resultados finais (desvio médio da tensão com respeito aos valores ideais) do Teste Piloto 1. Nos valores à direita pode-se ver como em alguns casos a correção é feita na direção certa (ciclos 1 e 2). Já no ciclo 3, os valores iniciais estavam mais próximos dos valores iniciais que as tensões corrigidas. De qualquer forma, o desvio médio obtido antes e depois da correção para cada canal demonstra que o uso do sistema neural artificial pode trazer benefícios. Em ambos os canais, os valores de desvio médio demonstra uma aproximação dos valores ideais (a validade deste teste será questionada no próximo capítulo).

Ciclo	Tensão Inicial (V)		Correção		Tensão Corrigida		Desvio Absoluto	
	Fem.	Per.	Fem.	Per.	Fem.	Per.	Fem.	Per.
1	46	49	24	24	70	73	4	1
2	63	64	12	14	75	78	1	4
3	60	60	-14	-11	46	49	28	25
<u>Desvio Médio Inicial (V)</u>			<u>Fem. : 32.1</u>		<u>Per. : 31.3</u>			
<u>Desvio Médio Corrigido</u>			<u>Fem. : 18.5</u>		<u>Per. : 17.7</u>			

Tabela 12 - Valores de tensão corrigidos pela rede neural baseado no movimento produzido pela tensão inicial (Teste Piloto 1). São mostrados em detalhe apenas três dos doze ciclos de teste. O desvio absoluto é a diferença absoluta entre a tensão aplicada e o valor ideal para cada canal (o valor ideal para a sessão de testes foi 74V para ambos canais). Os desvios médios denotam a média aritmética dos desvios para os doze ciclos. Fem. = femoral; Per. = peroneal.

6.1.2 Teste Piloto 2

6.1.2.1 Problemas Encontrados

1. Neste teste, existia a intenção de se fazer o treinamento da rede, e teste da mesma em modo automático, na mesma sessão. Entretanto, o treinamento da rede levou mais do que os estipulados 30 min máximos (mesmo num Pentium 75MHz!). Considerando que uma hora foi gasta na obtenção dos arquivos de treinamento (15 ciclos), treinamento e teste da rede implicaria em uma sessão de mais de 3h. Esta duração é inaceitável em se tratando de um sistema para pacientes medulares. O sistema foi interrompido e o treinamento da rede foi deixado para o dia seguinte (levou 1.5 h num DX2/66MHz). Para todos os sistemas desenvolvidos a partir deste teste, a obtenção de exemplos para treinamento foi feita em um dia, e o treinamento

da rede e testes em outros dois dias. Este problema também estimulou a aceleração do aprendizado (veja mais abaixo).

2. O programa havia sido preparado para lidar com uma largura de pulso (LP) máxima de 550 μ s. Este valor mostrou-se baixo em alguns casos (usando-se a frequência de 25Hz). O programa foi modificado para suportar uma LP máxima de 1000 μ s, e para aceitar um valor até 2000 μ s se o usuário assim desejar.

3. Havia estimulação muito prolongada para o quadriceps durante a fase de apoio. Isto causou fadiga muito cedo nos testes. Para resolver este problema, a estimulação femoral durante o apoio foi eliminada por completo. Isto só pôde ser feito por que o paciente conseguiu manter-se em pé apoiado na perna não estimulada e nas barras paralelas.

4. Recalibração dos goniômetros era necessária sempre que o programa era interrompido. Isto aconteceu por que as constantes de calibração não estavam sendo gravadas em arquivos. Este problema foi resolvido, mas recalibração é ainda necessária cada vez que os goniômetros saem do lugar (devido ao próprio movimento, ou por que eles tinham que ser tirados e recolocados quando, por exemplo, o paciente precisava ir ao banheiro). Esta é, aliás, a maior limitação dos goniômetros flexíveis produzidos pela Penny&Giles.

5. Em alguns casos (aproximadamente 1% dos dados totais) foram observados valores que indicavam perda do sinal proveniente dos eletrogoniômetros (foi encontrado um mal contato no sistema). Foi então feita uma pequena alteração na rotina de amostragem: Sempre que uma perda de contato era detectada (o sinal amostrado saía claramente da faixa de calibração), seria usada a média entre os valores amostrados antes e depois do quadro indesejado (em todos os casos o sinal indesejado durou apenas um quadro de amostragem; em S1, 1 ciclo = 24 quadros).

6.1.2.2 Desempenho do Sistema

Foram obtidos quinze arquivos durante a sessão de testes. Destes, doze foram usados para treinamento e três para testes (escolhidos aleatoriamente). Os testes feitos não incluíram teste automático devido aos problemas acima descritos. O ciclo de referência foi obtido com uma LP de 300 μ s para o quadriceps e 650 μ s para o canal peroneal.

Os resultados dos testes são mostrados na Tabela 13. Pode-se ver a melhora significativa (apesar do número reduzido de ciclos de teste) produzida pela rede neural através da drástica queda no desvio médio com respeito aos valores ideais (compare o desvio médio inicial com o desvio médio corrigido).

Ciclo	LP Inicial (μ s)		Correção		LP Corrigida		Desvio Absoluto	
	Fem.	Per.	Fem.	Per.	Fem.	Per.	Fem.	Per.
1	50	50	200	747	250	797	50	147
2	250	100	67	653	317	753	17	103
3	200	400	16	283	316	683	16	33
<u>Desvio Médio Inicial (μs)</u>			<u>Fem. : 133.</u>		<u>Per. : 467.</u>			
<u>Desvio Médio Corrigido</u>			<u>Fem. : 27.7</u>		<u>Per. : 94.3</u>			

Tabela 13 - Valores de LP corrigidos pela rede neural baseado no movimento produzido pela LP inicial (Teste Piloto 2). Para o calculo do desvio absoluto foram usados os valores de 300 μ s para o quadriceps e 650 μ s para o canal peroneal.

6.1.2.3 Aceleração do Aprendizado

Para acelerar o aprendizado da rede neural, foram manipulados a taxa de aprendizado e o domínio inicial dos pesos sinápticos e **bias** (a inclusão de um **bias** variável é opcional na retro-propagação). Algumas das combinações usadas são mostradas na Tabela 14. Na coluna mais à esquerda, é mostrada a faixa da taxa de aprendizado e o tipo de relação entre a taxa e o número de saídas com erro maior que a tolerância (o melhor desempenho foi obtido com funções lineares). Por exemplo, no segundo item da tabela, sempre que $Nerr/Ns$ é menor que $1/3p$ (veja as definições na legenda da tabela), a taxa varia linearmente com respeito a $Nerr$ dentro da faixa (0, 1.0). Se $Nerr/Ns$ é maior ou igual a $1/3p$, a taxa de aprendizado é constante e igual a 1.5. Nas duas colunas centrais, são mostrados os domínios iniciais dos valores aleatórios para os pesos sinápticos (W) e para os termos **bias** (B). Na coluna mais à direita, é mostrado o número de iterações quando a rede atingiu um erro menor que a tolerância, ou quando o treinamento foi interrompido por ser muito lento.

No último item da Tabela 14, além da manipulação dos elementos mencionados acima, foi feita a remoção de dados indesejáveis nos vetores de entrada da rede usando-se a técnica mencionada acima (seção 6.1.2.1, item 5). Fica claro o aumento da velocidade de aprendizado ao ser melhorado o sinal de treinamento. Por ser a opção mais rápida, a combinação de parâmetros mostrada no último item foi usada mais tarde no sistema experimental final.

TAXA DE APRENDIZADO	$[W]_0$	$[B]_0$	ITERAÇÕES
(0,0.95], Linear	(-1,+1)	(-1,+1)	21800, 18000
(0,1.0), Linear ==> Nerr/Ns<1/3p 1.5 ==> Nerr/Ns>=1/3p	(-1,+1)	(-1,+1)	40000*
(0,1.0), Linear ==> Nerr/Ns<1/3p 1.2 ==> Nerr/Ns>=1/3p	(-1,+1)	(-1,+1)	42000*
(0,1.0), Linear ==> Nerr/Ns<1/3p 1.1 ==> Nerr/Ns>=1/3p	(-1,+1)	(-1,+1)	25700
(0,1.0), Linear ==> Nerr/Ns<1/3p 1.1 ==> Nerr/Ns>=1/3p	(-3,+3)	(-2,+2)	14300 8420
(0,1.0), Linear ==> Nerr/Ns<1/3p 1.1==> Nerr/Ns>=1/3p; Rm=1/3Ro	(-3,+3)	(-2,+2)	11000
(0,1.0), Linear ==> Nerr/Ns<1/3p 1.1==> Nerr/Ns > = 1/3p; Rm=2 Ro	(-3,+3)	(-2,+2)	30000*
(0,1.0), Linear ==> Nerr/Ns<1/3p 1.1 ==> Nerr/Ns>=1/3p	(-5,+5)	(-3,+3)	4410** 3980**

* Interrompido (Nerr x Ns ainda similar p)

** Dados de entrada indesejáveis foram removidos

Tabela 14 - Manipulação de parâmetros para a aceleração do aprendizado. Nerr = número de saídas com erro maior que a tolerância. Ns = número de sensores usados (=2, não incluindo interruptores). p = número de ciclos usados para treinamento. Rm = taxa de aprendizado para a camada escondida. Ro = taxa de aprendizado para a camada de saída.

6.1.3 Teste Piloto 3

Para treinamento foram obtidos setenta e sete ciclos. No entanto, durante a sessão de aquisição de arquivos, observou-se que o paciente apresentava dorsiflexão mesmo quando os valores de estimulação eram muito baixos. Isto indica que o uso de EENM poderia ser questionável neste caso. Para analisar o efeito da estimulação, vários ciclos foram obtidos sem qualquer estimulação, e sem o conhecimento do paciente. Uma amostra representativa dos dados é apresentada na Figura 36. Neste caso, o ciclo de referência foi obtido com uma estimulação com LP de 1.0 ms (2.0 ms foi o máximo permitido para este teste).

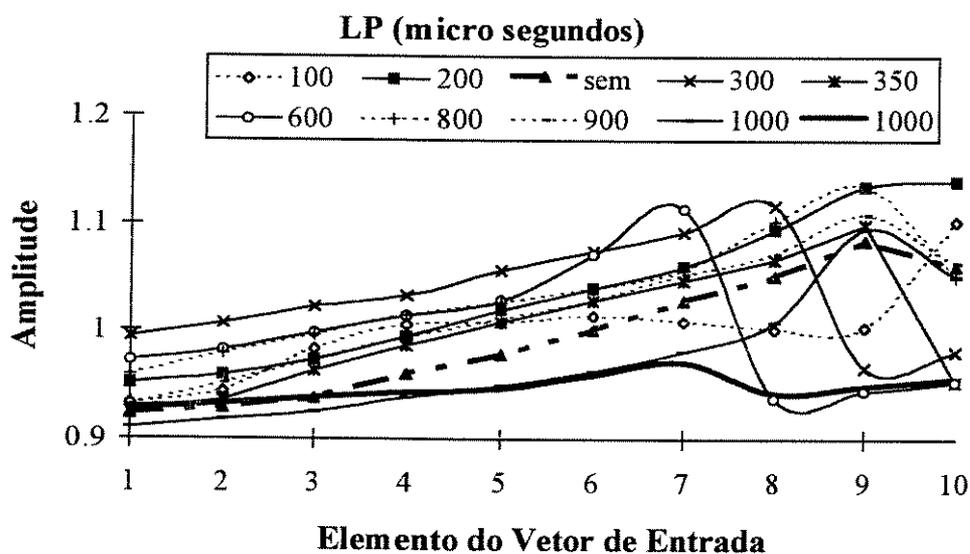


Figura 36 - Amostra dos movimentos produzidos com vária LPs (Teste Piloto 3). São mostrados os dados provenientes do goniômetro de tornozelo, como resultado da LP aplicada. O ciclo de referência é mostrado pela linha grossa contínua. Um ciclo obtido sem estimulação é mostrado pela linha grossa quebrada.

Na Figura 37, são mostrados os coeficientes de correlação entre as curvas da figura acima e a curva de referência (linha grossa contínua, Figura 36). Vê-se que não há diferença significativa entre o ciclo obtido sem qualquer estimulação e os outro ciclos. Além disso, um ciclo obtido com a mesma estimulação que produziu o ciclo de referência, 1000 s, tem menor coeficiente de correlação que o ciclo sem estimulação. Tudo isto implica que a EENM não faz qualquer diferença neste caso.

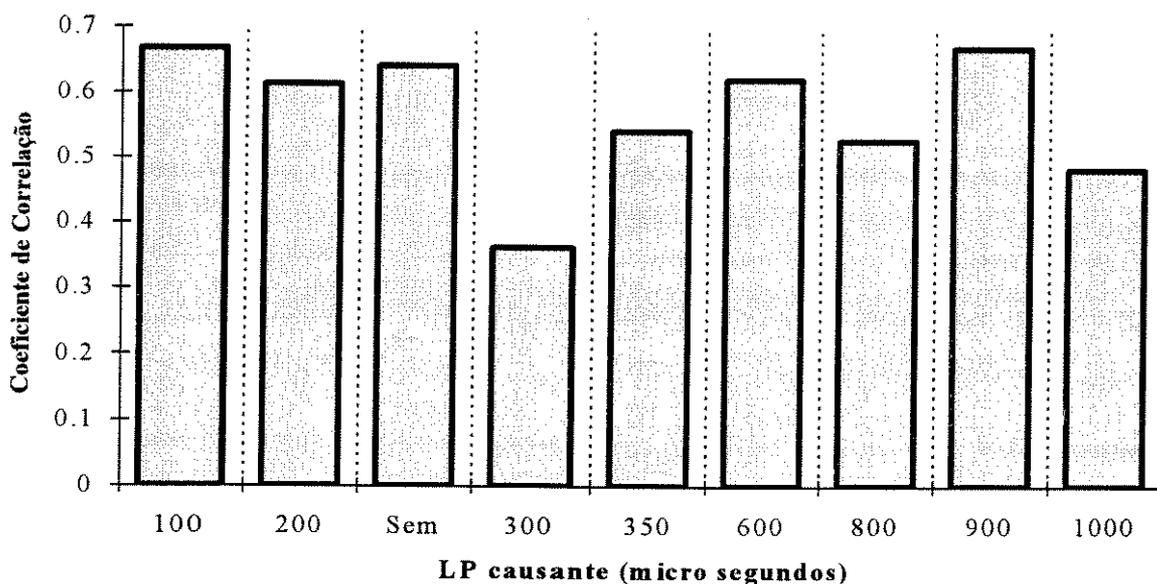


Figura 37 - Coeficientes de correlação entre as curvas da Figura 37 e a curva de referência.

6.2 SISTEMA EXPERIMENTAL

Foram calculados os coeficientes de correlação entre todos os ciclos de teste e os ciclos de referência para cada sessão. Na Figura 38, é mostrado o Teste Sem Adaptação (veja Capítulo 4) ao qual foi submetido o sistema S1 após treinamento 'off-line'. Para o caso da figura, o valor médio de crc^2 é 0.79. Este valor é calculado considerando apenas os ciclos não marcados por uma flecha.

TESTE SEM ADAPTAÇÃO
S1

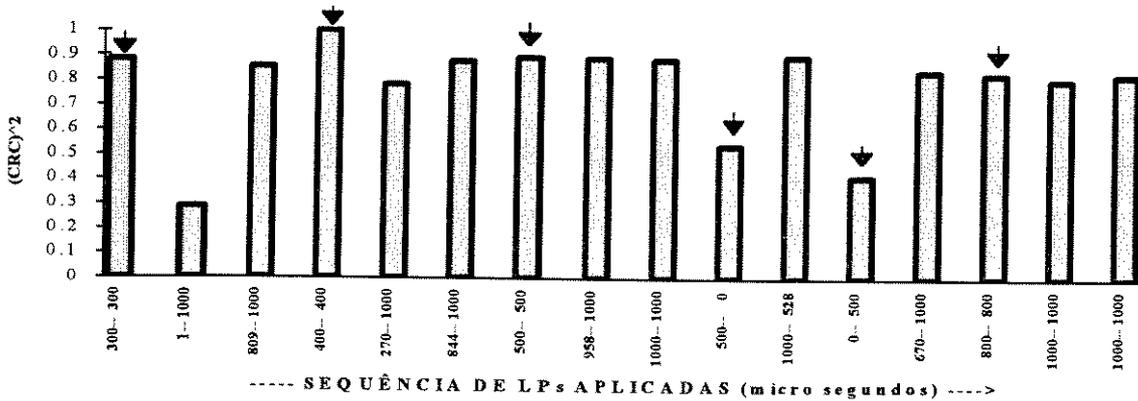


Figura 38 - Teste Sem Adaptação sináptica (TSA) para o sistema S1. As flechas denotam ciclos antes dos quais o operador ajustou as larguras de pulso. Eixo horizontal: LP aplicada (por exemplo, '809--1000' denota uma LP de 809 μ s aplicada no nervo femural e 1000 μ s aplicados no canal peroneal). Para o cálculo do valor médio de crc^2 , são considerados somente os ciclos não marcados por flechas. Valor médio de $crc^2 = 0.79$.

Nas Figuras 39, 40, e 41, é ilustrado o comportamento do sistema S1 durante aprendizado 'on-line'. Neste caso, o cálculo dos valores médios foi feito considerando-se apenas os ciclos marcados por P ou R. Assim, pode ser avaliada a resposta imediata do sistema ao aprendizado 'on-line'.

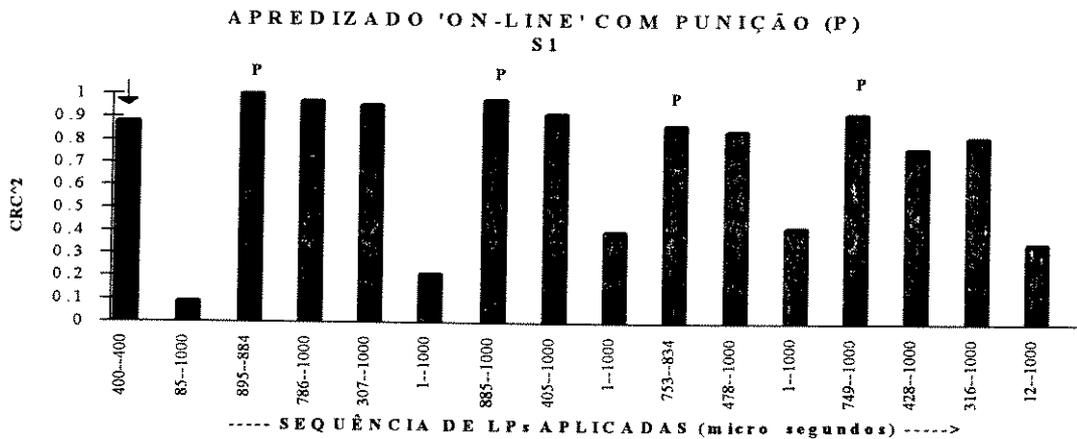


Figura 39 - Teste durante a aplicação de aprendizado 'on-line' com punição (P), sistema S1. Os ciclos marcados com P ocorrem imediatamente após a aplicação de punição devida ao fraco desempenho no ciclo anterior. Valor médio de $crc^2 = 0.91$.

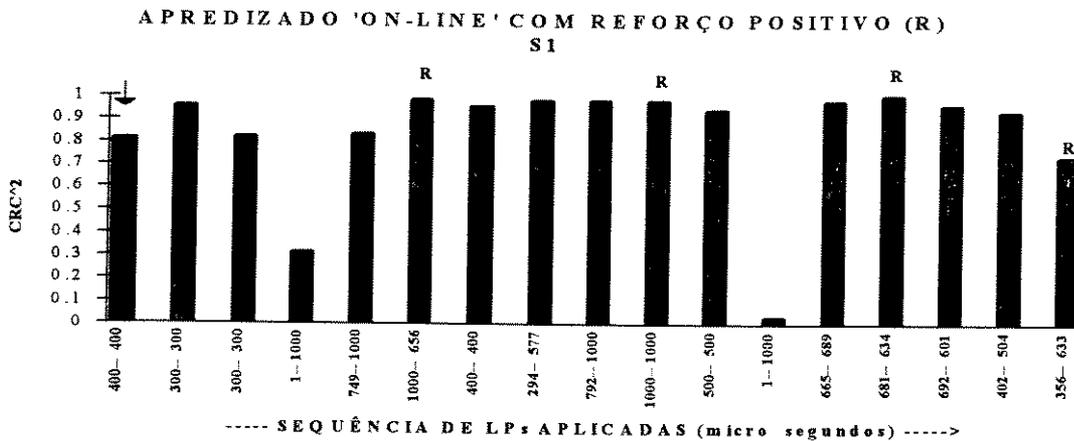


Figura 40 - Teste durante a aplicação de aprendizado 'on-line' com reforço positivo (R), sistema S1. Os ciclos marcados com R ocorrem imediatamente após a aplicação de reforço positivo devida ao bom desempenho no ciclo anterior. Valor médio de $crc^2 = 0.92$.

APREDIZADO 'ON-LINE' COM PUNIÇÃO (P)
E REFORÇO POSITIVO (R)

S1

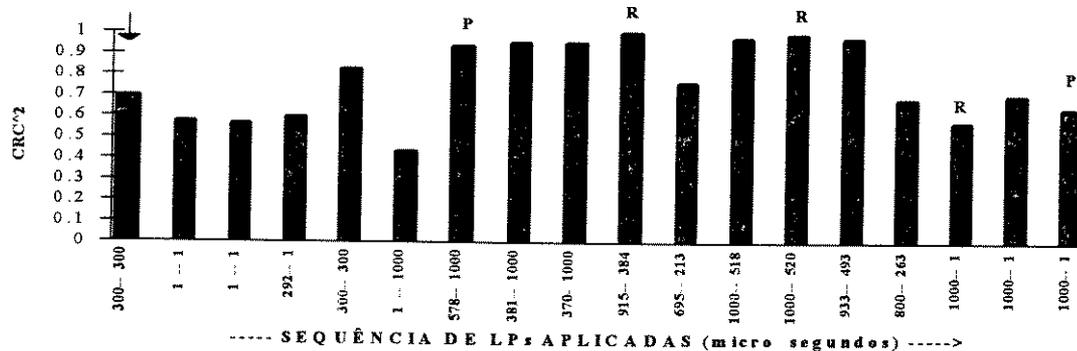


Figura 41 - Teste durante a aplicação de aprendizado 'on-line' com punição (P) e reforço positivo (R), sistema S1. Valor médio de $crc^2 = 0.83$.

Os mesmos testes mostrados acima foram feitos com o sistema S2. Os resultados finais para S1 e S2 são mostrados na Tabela 14.

TESTE	crc ² Médio	
	S1	S2
TSA no início da sessão	0.79, 0.69*	0.54
TSA após 40 ciclos de balanço	0.58	--**
Cada ciclo após punição (P)	0.91	0.37
Cada ciclo após reforço positivo (R)	0.92	0.59
Após punição e reforço positivo	0.83	--**
TSA após punição somente	0.65	0.25
TSA após reforço positivo somente	0.36, 0.46*	0.40
TSA após punição e reforço positivo	0.62	--**
MÉDIA TOTAL :	0.68	0.43

* testes feitos em dias diferentes

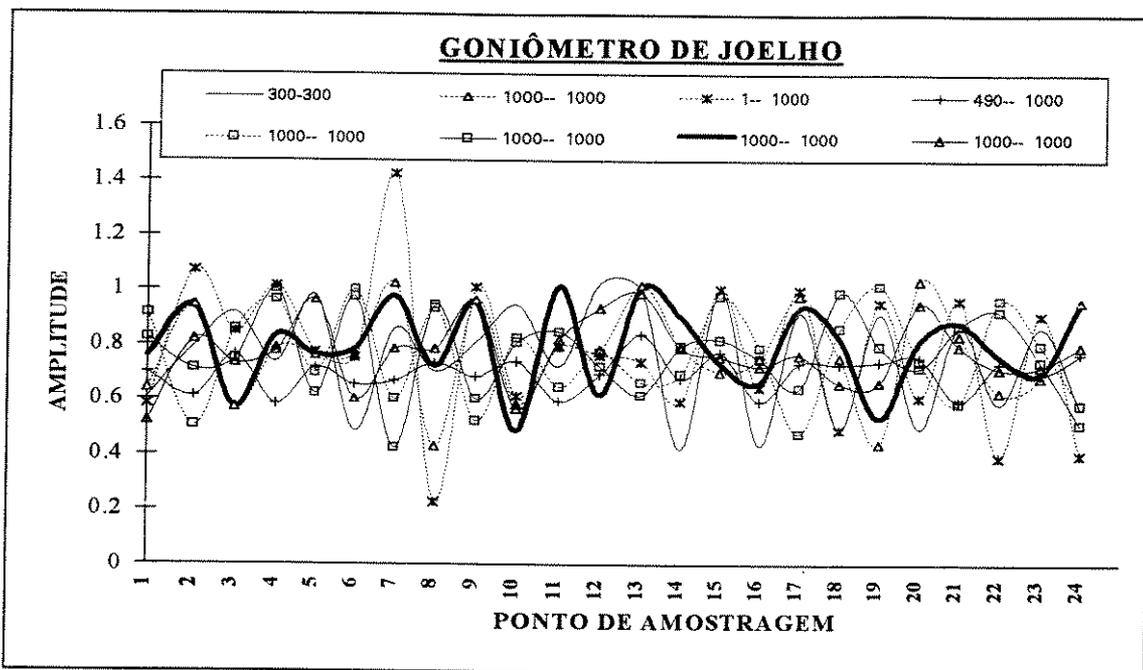
** não foi feito o teste; o paciente não estava disponível

Tabela 14 - Valores de crc^2 médios para os diferentes testes com os sistemas S1 e S2. Os maiores valores denotam melhor desempenho.

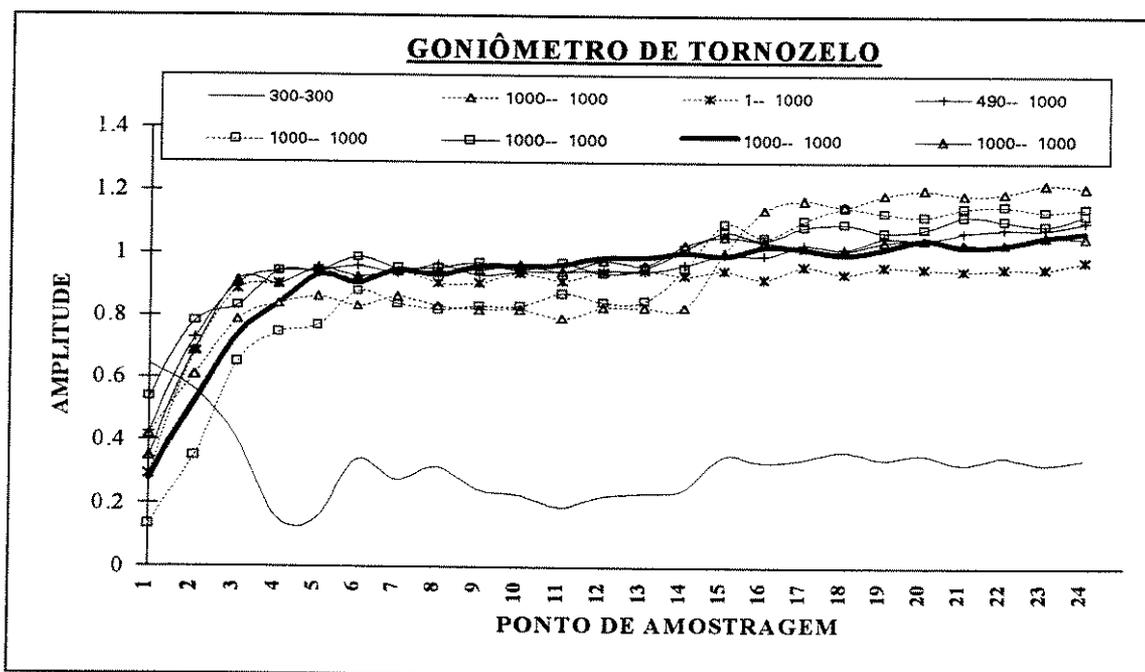
6.3 TESTE COM UM PROTÓTIPO

Baseado nos resultados da Tabela 14 acima (a ser discutidos no próximo capítulo), foi preparado um sistema final com as características do sistema S1. Para o sistema final, entretanto, foi restaurada a estimulação (fixa) durante a fase de apoio. O objetivo era fazer com que o paciente realmente caminhasse com a ajuda das barras paralelas. Devido ao reduzido comprimento das barras disponíveis, o paciente pôde dar somente um passo por vez, incluindo o movimento da perna não estimulada. As trajetórias observadas são mostradas na Figura 42.

As curvas referentes ao joelho mostram forte oscilação. Isto deve-se ao movimento oscilatório observado durante a marcha quando o paciente transferia o tronco de um lado para o outro. Isto significa que, para este caso, o uso exclusivo do reflexo de retirada para flexão do joelho e quadril não é suficiente. Esta oscilação pode comprometer a liberação do pé, ou, se ela for de grande amplitude, pode até comprometer a estabilidade mecânica do movimento (causando possível queda). Mais será dito sobre isto na discussão (esta reação foi observada no paciente em outra sessão de testes, cujos dados foram descartados). A má qualidade do sinal do joelho dificulta uma análise baseada em coeficientes de correlação. Para a avaliação do desempenho do sistema final, então, foram considerados apenas os dados referentes ao tornozelo. De qualquer forma, os movimentos foram suficientes para permitir a liberação do pé e a execução do balanço. Usando-se o melhor ciclo como referência (linha mais grossa na Figura 42b), foram calculados os valores de crc^2 . Os valores são mostrados na Figura 43.

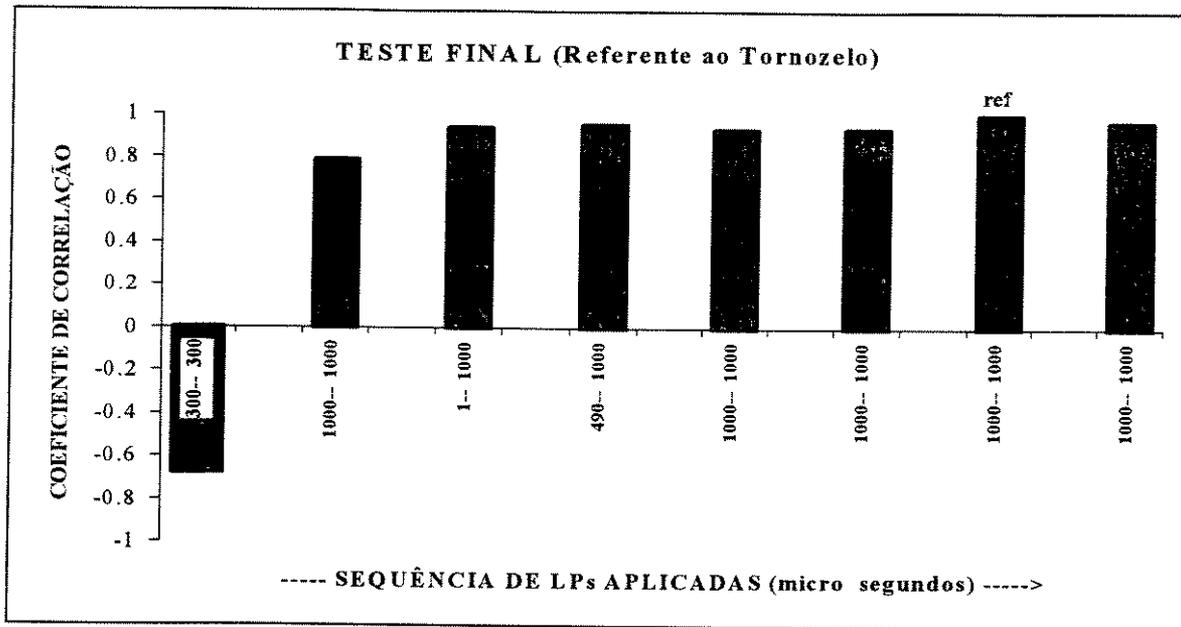


(a)



(b)

Figura 42 - Valores obtidos dos sensores de joelho (a) e tornozelo (b). O ciclo de referência é indicado pela linha sólida grossa nos dois gráficos. Valores maiores indicam flexão do joelho e dorsiflexão do tornozelo.



CRC Médio = 0.73

Figura 43 - Correlação entre os movimentos produzidos no tornozelo e o melhor ciclo observado (marcado com 'ref'), teste final com um protótipo.

CAPÍTULO 7

DISCUSSÃO

Tanto na parte teórica quanto na parte experimental desta tese, há vários aspectos que devem ser questionados. Isto é uma necessidade especialmente em se tratando de redes neurais artificiais, para as quais ainda não existe uma heurística aceita. Muito nesta área ainda é feito por tentativa e erro. Em primeiro lugar, as técnicas usadas para a avaliação do desempenho das redes devem ser justificadas e atacadas se necessário. Também deve ser estudado o modo de treinamento das redes. Ainda, do ponto de vista da engenharia biomédica, a interpretação dos resultados deve ser feita com reservas. Muitos dos bons resultados com sistemas de redes neurais provêm mais das propriedades de aproximação universal das redes (podendo a rede ser substituída por um sistema de regressão não linear), do que de sua capacidade de controle adaptativo (ainda que estes dois fatores estejam relacionados). Finalmente, a utilidade futura do sistema deve ser estudada.

7.1 SISTEMA TEÓRICO

7.1.1 Sobre a Avaliação do Desempenho

O uso da média dos quadrados dos erros (MQE) permite, como diz o nome, uma estimativa da distancia média entre duas curvas. Entretanto, há vários problemas referentes ao uso da MQE. Em primeiro lugar, como ocorre com todos os valores médios, os valores de desvio podem ser mais significativos que a própria média. Valores de desvio são, ainda, difíceis de interpretar, fazendo com que sejam ignorados (como foi feito nesta tese). Além disso, no caso da existência de uma relação linear entre as curvas comparadas, valores de

MQE podem acusar diferenças altíssimas, sendo que, num sistema de controle, bastaria multiplicar uma das curvas por uma constante para levar MQE em direção a zero. Este último fator é de extrema importância neste trabalho. Ora, se houver uma relação linear entre as previsões das redes e os valores verdadeiros, a saída das redes pode ser multiplicada (por exemplo) por uma constante, gerando um modelo mais apropriado para o controle. Eis, então, a utilidade do coeficiente de correlação de Pearson (*cr*c). Este coeficiente mede o grau de linearidade entre duas listas de dados. No caso de uma relação exatamente linear, é obtido o valor $cr = 1.0$. Isto ocorre mesmo que as listas de dados tenham sido geradas por sistemas não lineares.

Então, neste trabalho, deve ser dada mais importância aos valores de *cr*c, ainda que muitos trabalhos ainda insistam no uso de MQEs. Felizmente, os valores de MQE obtidos na parte teórica desta teste são de pequena magnitude e não afetam as conclusões finais. Por outro lado os valores de MQE não são totalmente inúteis (veja seção 7.1.3 abaixo).

Testes de covariância também têm demonstrado limitações, de modo que o uso de coeficientes de correlação (Billings e Voon, 1986), e testes baseados em Qui-quadrada (Leontaritis and Billings, 1987), são os mais recomendados (seção 2.5.3 em Brown e Harris, 1994).

O uso de um terço dos dados no teste das redes treinadas é prática comum. Ela permite avaliar a capacidade de generalização da rede. Ou seja, este teste permite avaliar se uma rede treinada apenas num subconjunto dos dados pode fazer o mapeamento com os dados restantes do conjunto (veja seção 7.1.3 abaixo). Já a simulação com dados patológicos permite avaliar se a rede treinada num conjunto de dados normais pode ser usada para controle em um domínio patológico. Este teste é importante na área de engenharia biomédica, especialmente ao considerar-se que a base de dados para a confecção e avaliação de modelos é reduzida (há poucas bases de dados para casos normais, e quase nada para casos patológicos). É necessário avaliar quanto pode ser feito com os dados disponíveis.

7.1.2 Possíveis Problemas no Treinamento das Redes

Ao treinar uma rede neural, vários fatores têm que ser considerados. Em primeiro lugar, deseja-se uma rede que possa fazer o mapeamento requerido. Isto já não é mais problema se um algoritmo de descendência por gradiente é usado; o treinamento só é interrompido quando o mapeamento é feito (com um erro mínimo). Em segundo lugar, a rede deve ser robusta e fazer boa generalização, ao mesmo tempo. Estes fatores são obtidos através da manipulação da tolerância e do uso de um extenso conjunto de dados de treinamento. O uso de valores de tolerância muito baixos, ou de conjuntos de treinamento muito pequenos, reduz a capacidade de generalização da rede. De fato, segundo Hush e Horne (1993), um conjunto de treinamento deve ter por volta de dez vezes o número de pesos sinápticos. Nesta tese, a maioria das redes no estudo teórico têm $4 \times 20 + 20 \times 5 = 180$ pesos. Isto significa que o conjunto de treinamento deveria ter (num caso ideal) $10 \times 180 = 1800$ pares entrada-saída. Considerando-se que o ciclo da marcha leva aproximadamente 1 s, isto implica uma amostragem em 1.8 kHz, um valor inaceitável para as variáveis de entrada usadas no modelo (normalmente, os sinais de forças de reação são captados em 200 Hz, e os ângulos em menos de 20 Hz; amostragens em frequências mais altas incluem muito ruído e pouco sinal aproveitável). Uma opção seria usar sinais amostrados nas frequências tradicionais, mas incluir dezenas de ciclos da marcha nos dados de treinamento. Infelizmente, os dados encontrados na literatura incluem não mais de dois ciclos.

Outro fator importante é o uso de um conjunto de dados de treinamento que seja representativo dos dados com os quais a rede terá que lidar. Neste trabalho, ao usar-se dados de todo o ciclo da marcha, este fator foi levado em conta.

7.1.3 Significado dos Resultados

Uma análise dos valores de MQE para o Teste 1 (Tabela 6, Capítulo 5) demonstra que a capacidade de generalização das redes é melhor na fase de balanço. Considerando-se o quadrado da tolerância ($(0.1)^2 = 0.01$), pode-se ver que os valores de MQE_B para as redes 6, 8, 10, 12, 14, e 16 estão próximos dos valores de tolerância, apesar de que a rede não foi treinada nos dados de teste. Já a generalização na fase de apoio não é boa. Para o Teste 2 (Tabela 11, Capítulo 5) os valores de MQE são altos para todas nas duas fases da marcha. O aumento na MQE (do Teste 1 para o Teste 2), indica que o treinamento das redes com dados normais não permite a elas fazer uma generalização do espaço patológico. Isto significa que se uma rede há de ser usada para o controle de uma situação patológica, a rede tem que treinada com dados representativos da patologia. Esta conclusão reforça resultados de estudos anteriores simulando outras patologias (Sepulveda *et al.* 1993).

Resultados gerais baseados no Índice de Desempenho (Figura 34, Capítulo 5) sugerem que uma rede neural para o controle da marcha por meio dos cinco músculos usados neste trabalho deve incluir memória de entradas passadas, e o uso das últimas saídas no vetor atual de entrada. Recursão no algoritmo de aprendizado pode trazer benefícios, mas o aumento no custo computacional é muito alto, de modo que o uso de recursão na retropropagação não é recomendável neste caso. Ainda, o uso de redes especializadas na fase de apoio ou de balanço é preferível ao uso de uma só rede para todo o ciclo. Isto resulta provavelmente do comportamento do sensor da força de reação (FR). Durante a fase de apoio, o neurônio correspondente a este sensor (camada de entrada, quarto neurônio), tem respostas variadas de acordo com este sinal. Já na fase de balanço, sua resposta é constante. Isto significa que uma rede treinada somente em dados da fase de balanço, ‘aprende’ a ignorar o sinal de FR (o neurônio correspondente não foi eliminado da rede neural). Já a rede treinada em todo o ciclo da marcha leva em conta os valores de FR independentemente da

fase em que eles ocorram (com a exceção da Rede 4, a ordem de apresentação dos pares de treinamento não faz diferença). Está é uma conclusão óbvia do ponto de vistas da biomecânica, mas é interessante ver que a uma rede neural responde a este fato.

Outro resultado importante refere-se ao fato de que a estrutura das redes tem pouco a ver com seu desempenho. Mudanças drásticas na estrutura das redes (intraconectividade na camada escondida; conectividade seletiva entre as camadas escondida e de saída) não geram mudanças drásticas no desempenho das redes.

7.1.4 Propostas Para o Futuro

Para aprimorar o modelo e a análise dos resultados, tendo em mente o possível uso do modelo em um sistema de EENM, os seguintes aspectos devem ser explorado no futuro:

- I. No treinamento, usar dados representativos da patologia do paciente que usará o sistema.
- II. Expandir o conjunto de dados para treinamento.
- III. Explorar outras combinações entre as diferentes redes testadas.
- IV. Aproximar o modelo às características de um sistema de EENM.

O último item consiste em fazer um mapeamento entre as saídas da rede e o verdadeiro sinal a ser usado pelo sistema de EENM. Outra opção é fazer o contrário, ou seja, utilizar sinais de EENM com um comportamento temporal similar ao dos músculos incluídos no modelo. Antes, é necessário estudar os movimentos produzidos por um sistema de EENM com os cinco músculos usados neste trabalho (ou outros de similar função).

7.2 SISTEMA EXPERIMENTAL

7.2.1 Sobre a Avaliação do Desempenho

Para o cálculo dos coeficientes de correlação, foi usado um ciclo de referência para cada sessão. Um dos problemas com este procedimento é a dificuldade para comparar resultados de dias diferentes. Ainda que ciclos de boa qualidade foram obtidos em todas as sessões incluídas na análise, com certeza alguns destes bons ciclos foram melhores que os outros (por 'bom', entenda-se similaridade a um passo normal). Para evitar este tipo de subjetividade, duas medidas podem ser tomadas no futuro. Primeiro, uma sessão pode ser usada somente para a obtenção de um ciclo a ser usado como referência mais tarde. Um problema com esta medida é a possibilidade de ciclos de sessões subsequentes serem melhores, mas, por isso, gerarem valores relativamente baixos de *crc*. Outra possibilidade, é o uso de dados angulares obtidos de uma pessoa normal, com os mesmos sensores (para reduzir as fontes de erro). Então, o ciclo normal seria usado como referência. Um dos problemas com esta técnica é que em muitos casos, o melhor ciclo que pode ser produzido com um paciente pode ter semelhança apenas marginal com um ciclo normal. Neste caso, todos os valores de *crc* seriam baixos, independente da qualidade do ciclo. Isto reduziria a diferença estatística entre os ciclos, dificultando qualquer análise.

Tendo estes problemas em mente, não devem ser consideradas significativas diferenças de crc^2 menores que 0.1. Vale enfatizar que este artifício não resolve o problema. É apenas uma alternativa que permite uma interpretação dos resultados.

7.2.2 Possíveis Problemas no Treinamento da Rede

No caso de um sistema de controle com uma planta extremamente variável no tempo, é quase impossível obter um conjunto de treinamento representativo de todo o espaço de dados. Além disso, se for levada em consideração a recomendação de Hush e Horne (1993), seriam necessários $10 \times (48 \times 30 + 30 \times 2) = 15000$ pares entrada-saída para S1! Este número de ciclos é inviável no caso de um paciente medular. Seriam necessários vários meses apenas para acumular dados para o treinamento da rede em modo 'off-line'. Esta é principal razão para o uso de um sistema 'on-line'. No caso 'on-line', como implica o termo, o aprendizado ocorre durante o uso do sistema de EENM com a rede neural.

Com respeito aos esquemas 'on-line', há vários fatores a serem considerados. Em primeiro lugar, está a questão da estabilidade do aprendizado. Estabilidade neste caso, refere-se à capacidade de uma rede neural de aprender dados novos, sem esquecer dados antigos. Com relação a este aspecto, é possível que as técnicas usadas para adaptação sináptica na punição e no reforço positivo comprometam o desempenho futuro da rede (veja seção 7.2.3 abaixo). Para reduzir este tipo de problema, modificações podem ser feitas no programa de controle. Por exemplo, ao executar a punição, o observador poderia determinar a mudança na magnitude dos pesos e a quantidade de pesos a serem modificados (ambos valores foram fixados em 10%), tendo como valor máximo os 10% usados neste trabalho. De qualquer forma, estudos futuros terão que incluir várias sessões de teste apenas para avaliar a estabilidade do aprendizado.

Um problema sério no esquema de aprendizado 'on-line' usado nesta tese, é a necessidade da interferência de um observador. Isto é aceitável num sistema experimental. Mas, num sistema futuro a ser usado fora do ambiente de laboratório, o controle deverá ser completamente automático. Nesta direção, o programa de controle pode ser modificado para

calcular valores de *crc* após cada passo (possivelmente usando dados normais como referência). Então, sempre que o valor de *crc* fosse maior que 0.8 (por exemplo), o sistema seria submetido a reforço positivo. Quando *crc* fosse menor que 0.5, seria aplicada a punição. Outra opção é incluir o próprio valor de *crc* no vetor de entrada da rede neural. Ainda, técnicas de aprendizado por reforço desenvolvidas por outros grupos podem ser exploradas (e.g., Zhang e Grant, 1992).

7.2.3 Significado dos Resultados

Variações no valor médio para S1 do início de uma sessão até 40 ciclos depois (Tabela 14, Capítulo 6), indicam que o desempenho da rede neural degrada-se no decorrer da sessão de teste. Isto provavelmente resulta da fadiga muscular e/ou habituação do reflexo de retirada. Estes fatores colocam a planta num espaço de dados em que a rede não foi treinada. Para reduzir este problema, a rede neural teria que ser treinada também com dados obtidos após a observação de fadiga ou habituação. De qualquer forma, devido a esta degradação do desempenho, os valores referentes aos testes TSA após aprendizado 'on-line' devem ser comparados com os valores de *crc* após os 40 ciclos (segundo item, Tabela 14), já que o aprendizado 'on-line' foi feito tipicamente durante trinta a cinquenta ciclos. Desta maneira, pode-se ver que a aplicação de punição, e de punição combinada com reforço positivo (sexto e oitavo itens na Tabela 14), não comprometem a estabilidade da rede neural. Já no caso da aplicação de reforço positivo somente (sétimo item), o desempenho da rede claramente cai.

Os valores altos para os testes durante o aprendizado 'on-line' (itens terceiro a quinto da Tabela 14), demonstram a melhoria imediata produzida pela aplicação de punição e reforço positivo.

Uma comparação entre os sistema S1 e S2, indicam clara superioridade do sistema S1. Isto ocorreu apesar de que o conjunto de dados de treinamento para S2 foi maior e

melhor distribuído que para S1. O pobre desempenho de S2 esta provavelmente relacionado a algumas características do sistema. Neste sentido, há duas diferenças fundamentais entre S1 e S2: o uso de um goniômetro de quadril em S2 ao invés de um no tornozelo em S1; e, em S2, na segunda metade da fase de balanço, somente o canal femoral está ativado. Em S2, ambos goniômetros (joelho e quadril) geram sinais muito parecidos. Flexão e extensão ocorrem simultaneamente nas duas articulações (em S2 somente), de forma que é redundante a informação de um dos sensores. Além disso, na segunda metade do balanço, extensão do joelho e quadril ocorrem em S2 com ou sem estimulação. Se a estimulação femoral é adequada, ao ser desativado o canal peroneal, a contração do reto femoral não é suficiente para manter o quadril flexionado, mas sim para estender o joelho, resultando em extensão simultânea do joelho e do quadril. Por outro lado, se a estimulação femoral é fraca, a gravidade encarrega-se de estender o quadril e o joelho. Então fica difícil determinar se o nível de estimulação na segunda metade do balanço é apropriada ou não. Se a tarefa já é difícil para um observador humano, é pouco provável que uma rede neural artificial tenha mais sucesso. Já no caso de S1, há claras diferenças nos sinais de ambos os goniômetros. Para cada goniômetro também há claras diferenças entre um ciclo com estimulação adequada e outro com estimulação sub-suficiente. Em resumo, a informação disponível a S1 é mais completa que para S2.

De qualquer forma, há dois aspectos em S2 que devem ser incorporados a S1: redução da duração da estimulação, e o uso de um conjunto de treinamento mais abrangente.

7.2.4 Propostas Para o Futuro

De acordo com a análise acima, sistemas para estudo futuro devem incluir os seguintes elementos:

- I. Na segunda fase do balanço, deve ser mantida a flexão do quadril, por meio de estimulação peroneal comum ou por outra técnica.
- II. Reduzir a duração da estimulação para retardar a fadiga muscular e a habituação do reflexo.
- III. Goniômetros devem ser usados nas três articulações (quadril, joelho, e tornozelo).
- IV. Incluir dados de treinamento que sejam representativos de uma planta com fadiga muscular e a habituação do reflexo.
- V. Inclusão de ativação automática do aprendizado 'on-line'.

Além disso, devem ser estudadas outras formas de retardamento da fadiga muscular e da habituação de reflexos. Isto implica uma pesquisa de caráter fisiológico, mas geraria melhores maneiras de controlar a planta. Neste sentido, devem ser exploradas as idéias de recrutamento mencionadas no início da tese, além do estudo de diversas formas de modulação do sinal de estimulação. Estes estudos devem ser acompanhados de medições biomecânicas que permitam uma avaliação mais precisa da relação entre as entradas e a resposta da planta. O mesmo deve ser feito tendo em mente a produção de movimentos suaves.

Tudo isto facilitaria a confecção de um sistema neural artificial para a produção da marcha por meio de EENM.

CAPÍTULO 8
CONCLUSÃO E SUGESTÕES
PARA TRABALHOS FUTUROS

Neste trabalho, pioneiro a nível mundial, foi explorado o uso de redes neurais artificiais para o controle da marcha produzida por EENM. Com respeito a um sistema hipotético de cinco canais e a um sistema experimental de dois canais, foram estabelecidos alguns critérios relacionados à estrutura das redes neurais, ao treinamento das redes, e à avaliação do desempenho do sistema.

Entretanto, de acordo com os resultados obtidos, muito trabalho ainda precisa ser feito antes que um sistema neural artificial baseado nesta tese seja usado fora do ambiente laboratorial. Pesquisas são necessárias com respeito tanto ao esquema de controle quanto ao comportamento da planta (sistema neuromuscular sob estimulação elétrica).

Como primeira extensão ao trabalho teórico aqui descrito, os seguintes aspectos devem ser explorados:

- i. No treinamento, usar dados representativos da patologia do paciente que usará o sistema.
- ii. Expandir o conjunto de dados para treinamento.
- iii. Explorar outras combinações entre as diferentes redes testadas.
- iv. Aproximar o modelo às características de um sistema de EENM.

Ainda, se necessário for, novos critérios para a avaliação do desempenho das redes neurais devem ser investigados. Isto se aplica também aos sistemas experimentais desenvolvidos neste trabalho.

Para dar continuidade ao trabalho experimental, os primeiros passos devem levar em consideração os seguintes fatores:

- I. Reduzir a duração da estimulação para retardar a fadiga muscular e a habituação de reflexos.
- II. Goniômetros devem ser usados nas três articulações (quadril, joelho, e tornozelo).
- III. Incluir dados de treinamento que sejam representativos de uma planta com fadiga muscular e a habituação de reflexos.
- IV. Inclusão de ativação automática do aprendizado 'on-line'.
- V. Mais estudos sobre a estabilidade do aprendizado e sobre as técnicas de aprendizado 'on-line'.
- VI. Investigação detalhada dos efeitos da estimulação na planta controlada. Devem ser exploradas variações da estimulação no tempo e no espaço, sempre monitorando o comportamento da planta.

Tudo isto deve ser feito sem comprometer a simplicidade computacional do sistema de controle.

BIBLIOGRAFIA

- Aidley, D.J. (1989). *'The physiology of excitable cells'*. Cambridge University Press, NY.
- Albus, J.S. (1991). 'Outline of a theory of intelligence'. *IEEE Trans. Sys. Man and Cybern.*, 21: 473-509.
- Aleksander, I. (1989). *'Neural computing architectures: The design of brain-like machines'*. The MIT Press, Cambridge, MA.
- Alvarez, S.E. (1985). 'Functional assessment and training'. In *'Spinal Cord Injury'*, (ed.) Adkins, H.V. Churchill Livingstone, NY.
- Amirikian, B.R., Lukashin, A.V. (1992). 'A neural network learns trajectory of motion from the least action principle'. *Biol. Cybern.*, 66: 261-264.
- Anderson, C.W. (1989). 'Learning to control an inverted pendulum using neural networks'. *IEEE Control Sys. Mag.*, Abril, pp 31-37.
- Andrews, B.J. (1990). 'A prototype modular hybrid FES orthotic system for paraplegics'. *Proc. Advances in External Control of Human Extremities X*, Dubrovnik, pp 187-196.
- Andrews, B.J., Bajd, T. (1984). 'Hybrid orthoses for paraplegics'. *Proc. (supplement) Advances in External Control of Human Extremities VIII*, Dubrovnik, pp 55-59.
- Andrews, B.J., Baxendale, R.H., Barnett, R.W., Philips, G.F., Yamazaki, T., Paul, J.T., Freeman, P.A. (1988). 'Hybrid FES orthosis incorporating closed-loop control and sensory feedback'. *J. Biomed. Eng.*, 10: 189-195.
- Antsaklis, P.J., Passino, K.M. (eds.) (1992). *'An introduction to intelligent and autonomous control'*. Kluwer Academic Publishers, Boston.
- Barto, A.G., Sutton, R.S., Anderson, C.W. (1983). 'Neuronlike adaptive elements that can solve difficult learning control problems'. *IEEE Trans. Sys. Man and Cybern.*, 13: 834-846.
- Berenji, H.R., Khedkar, P. (1992). 'Learning and tuning fuzzy logic controllers through reinforcement'. *IEEE Trans. Neural Networks*, 3: 724-740.
- Best, J.A. van, Pronk, C.N.A., Mechelse, R.P., Eijndhoven, A. (1983). 'A method for two dimensional multi-segmental kinematic and kinetic analysis of normal and pathologic human gait'. *Med. Prog. Through Tech.*, 10: 143-154.
- Beuter, A., Flashner, H., Arabyan, A. (1986). 'Phase plane modeling of leg motion'. *Biol. Cybern.*, 53: 272-284.
- Bigland, B., Lippold, O.C.J. (1954). 'The relation between force velocity and integrated electrical activity in human muscles'. *J. Physiol.*, 123: 214-224.
- Billings, S.A., Voon, W.S.F. (1986). 'Correlation based model validity tests for nonlinear models'. *Int. J. Control*, 44: 235-244.

- Bjorklund, A., Stenevi, U (1979). 'Regeneration of monoaminergic and cholinergic neurons in the mammalian central nervous system'. *Physiol. Rev.* 59: 62-99.
- Bouisset, S., Goubel, F. (1972). 'EMG and muscle force in normal motor activities'. In *New Developments in EMG and clinical neurophysiology*, (ed.) Desmedt, J.E. S. Karger, Basel, pp. 547-583.
- Bromley, I (1985). '*Tetraplegia and paraplegia: A guide for physiotherapists*'. Churchill Livingstone, Edinburgh.
- Brooks, V.B. (1986). '*The neural basis of motor control*'. Oxford University Press, Oxford.
- Brooks, A.L., Fowler, S.B. (1964). 'Axillary artery thrombosis after prolonged use of crutches'. *J. Bone and Joint Surg.*, 46: 863-864.
- Brown, M Harris, C (1994). '*Neurofuzzy modeling and control*'. Prentice Hall, London.
- Calvin, W. (1990). '*The ascent of mind: Ice age, climates, and the evolution of intelligence*'. Bantam Books, NY.
- Capildeo, R., Maxwell, A. (1984). '*Progress in rehabilitation: Paraplegia*'. MacMillan Press, London.
- Carpenter, G.A. (1989). 'Neural network models for pattern recognition and associative memory'. *Neural Networks*, 2: 243-257.
- Carpenter, G.A, Grossberg, S. (1990). 'ART 3: Hierarchical search using chemical transmitters in self-organizing pattern recognition architectures'. *Neural Network*, 3: 129-152.
- Carpenter, G.A, Grossberg, S. (1988). 'The ART of adaptive pattern recognition by a self-organizing neural network'. *IEEE Computer*, Março, pp 77-88.
- Carpenter, G.A, Grossberg, S, Rosen, D.B. (1991). 'ART 2-A: An adaptive resonance algorithm for rapid category learning and recognition'. *Neural Networks*, 4: 493-504.
- Cliquet Jr., A. (1992a). 'Man-machine control systems for restoring movement to the paralysed limbs'. In: *4th Vienna International Workshop on Functional Electrical Stimulation*. International Society for Artificial Organs, Vienna, Austria, pp. 123-126.
- Cliquet Jr., A. (1992b). 'A neural network voice-controlled neuromuscular electrical stimulation system for tetraplegics'. *Rehabilitation Engineering Society of North America - RESNA*. RESNA Press, Washington, D.C., pp. 29-31.
- Cliquet Jr., A (1988). '*Paraplegic locomotion with neuromuscular electrical stimulation based systems - A feasibility study*'. Tese de doutorado, Bioengineering Unit, University of Strathclyde, Glasgow.
- Cliquet Jr., A., Baxendale, R.H., Andrews, B.J. (1989). 'Paraplegic locomotion and its metabolic energy expenditure'. In: *Comprehensive Neurologic Rehabilitation - Vol. 3, Neuromuscular Stimulation: Basic Concepts and Clinical Implications*. (Ed.) Rose, Jones, Vrbotá. Demos, NY, pp. 139-146.

- Cliquet Jr., A., Nene, A.V., Barnett, R., Andrews, B.J. (1986). 'Fns augmentation of reciprocating hkafo and kafo braces'. In: *2nd Vienna International Workshop on Functional Electrical Stimulation*. International Society for Artificial Organs, Vienna, Ausria, pp. 83-86.
- Coiton, Y., Gilhodes, J.C., Velay, J.L., Roll, J.P. (1991). 'A neural network model for intersensory coordination involved in goal-directed movements'. *Biol. Cybern.*, 66: 167-176.
- Cowan, J.D. Sharp, D.H. (1988). 'Neural nets'. *Quarterly Rev. Biophys.*, 21: 365-427.
- Crowninshield, R.D., Brand, R.A. (1981). 'A physiologically based criterion of muscle force prediction in human locomotion'. *J. Biomech.*, 14: 793-801.
- Davy, D.T., Audu, M.L. (1987). 'A dynamic optimization technique for predicting muscle forces in thje swing phase of gait'. *J. Biomech.*, 20: 187-201.
- Dean, J. (1990). 'Coding proprioceptive information to control movement to a target: Simulation with a simple neural network'. *Biol. Cybern.* 63: 115-120.
- Douglas, R., Larson, P.F., D'Ambrosia, R., McCall, R.F. (1983). 'The LSU reciprocating gait orthosis'. *Orthopedics*, 6: 834-839.
- Durfee, W.K., Hausdorff, (1990). 'Regulating knee joint position by combining electrical stimulation with a controllable friction brake'. *Ann. Biomed. Eng.*, 18: 575-596.
- Eccles, J.C. (1957). *The physiology of nerve cells*. Johns Hopkins University Press, Baltimore.
- Ewins, D.J., Taylor, P.N., Crook, S.E., Lipczynski, R.T., Swain, I.D. (1988). 'Practical low cost stand/sit system for mid-thoracic paraplegics'. *J. Biomed. Eng.*, 10: 184-188.
- Flashner, H., Beutner, A., Arabyan, A. (1987). 'Modeling of control and learning in a stepping motion'. *Biol. Cybern.* 55: 387-396.
- Fournier, A., Goldberg, M, Green, B. (1984). 'A medical evaluation of the effects of computer assisted muscle stimulation in paraplegic patients'. *Orthopedics*, 7: 1129-1133.
- Fu, K.S. (1971). 'Learning control systems and intelligent control systems: An intersection of artificial intelligence and automatic control'. *IEEE Trans. Auto. Control*, 16: 70-72.
- Gribbin, J., Gribbin, M. (1990). *Children of the ice: Climate and human origins*. Basil Blackwell Inc., Oxford.
- Grillner, S., Zangger, P. (1984). 'The effect of dorsal root transection on the efferent motor pattern in the cat's hindlimb during locomotion'. *Acta Physiol. Scand.* 120: 393-405.
- Grossberg, S. (ed.) (1988a). *Neural networks and artificial intelligence*. The MIT Press, Cambridge, MA.
- Grossberg, S. (1988b). 'Nonlinear neural networks: Principles, mechanisms, and architectures'. *Neural Networks*, 1: 17-61.

- Guttman, R. (1976). *'Spinal cord injuries, comprehensive management and research'*. Blackwell Scientific, Oxford.
- Guyton, A.C. (1986). *'Textbook of medical physiology'*. W.B. Saunders Co., Philadelphia.
- Handa, Y., Hoshimiya, N., Iguchi, Y., Oda, T. (1989). 'Development of percutaneous intramuscular electrode for multichannel FES system'. *IEEE Trans. Biomed. Eng.*, 36: 705-710.
- Hambrecht, F.T. (1992). 'A brief history of neural prostheses for motor control of paralyzed extremities'. In *'Neural prosthesis: Replacing motor function after disease or disability'*, cap. 1, (ed.) Stein, B.R., Peckham, P.H., Popovic, D.P. Oxford University Press, Oxford.
- Harris, C.J. (ed.) (1994). *'Advances in intelligent control'*. Taylor & Francis, London.
- Hatze, H. (1978). 'A general myocybernetic control model of skeletal muscle'. *Biol. Cybern.*, 28: 143-157.
- Hausdorff, J.M., Dufee, W.K. (1988). 'Hybrid FES gait orthosis using controllable damping elements'. *Proc. ICAART '88*, Montreal, pp 348-349.
- Heller, B. (1992). *'The production and control of FES swing-through gait'*. Tese de doutorado, Bioengineering Unit, University of Strathclyde, Glasgow.
- Henneman, E. (1981). 'Recruitment of motoneurons: The size principle'. In 'Motor unit types: recruitment and plasticity in health and disease', (ed.) Desmedt, J.E. *Prog. Clin. Neurophysiol.*, 9: 26-90.
- Hof, A.L., Pronk, C.N.A., van Best, J.A. (1987). 'Comparison between EMG to force processing and kinematic analysis for the calf muscle moment in walking stepping'. *J. Biomech.*, 20: 167-178.
- Hof, A.L., van den Berg, J.W. (1977). 'Linearity between the weighted sum of the EMGs of the human triceps surae and the total torque'. *J. Biomech.*, 10: 167-178.
- Holland, J.M. (1975). *'Adaptation in natural and artificial systems'*. University of Michigan Press, Ann Arbor.
- Hopfield, J.J. (1982). 'Neural networks and physical systems with emergent collective computational abilities'. *Proc. Nat. Acad. Sci.*, 79: 2554-2558.
- Hunt, K.J., Sbarbaro-Hofer, D., Zbikowski, R., Gawthrop, P.J. (1992). 'Neural networks for control systems - A survey'. *Automatica*, 28: 1083-1112.
- Hush, D.R., Horne, B.G. (1993). 'Progress in supervised neural networks: What's new since Lippmann?'. *IEEE Sig. Proc. Mag.*, Janeiro, pp 8-39.
- Iansek, R., Redman, S.J. (1973). 'An analysis of the cable properties of spinal motoneurons using a brief intracellular current pulse'. *J. Physiol.*, 234: 613-636.
- Inman, V.T., Ralston, H.J., Saunders, J.B., Feinstein, B., Wright, W.B. (1952). 'Relation of human electromyogram to muscular tension'. *Electroencephal. Clin. Neurophysiol.*, 4: 187-194.

- Inman, V.T., Ralston, H.J., Todd, F. (1981). *'Human Walking'*, Williams & Wilkins, Baltimore, p11.
- Jack, J.J.B., Noble, D., Tsien, W.(1983). *'Electric current flow in excitable cells'*. Oxford University Press, NY.
- Jaeger, R.J. (1986). 'Design and simulation of closed-loop electrical estimation orthoses for restoration of quiet standing in paraplegia'. *J. Biomech.*, 19: 825-835.
- Kalveram, K.T. (1991). 'Controlling the dynamics of a two-jointed arm by central pattering and reflex-like processing'. *Biol. Cybern.* 65: 65-71.
- Kandel, E.R., Schwartz, J.L. (1985). *'Principles of neural science'*. Elsevier, NY.
- Katz, B. (1966). *'Nerve, muscle and synapse'*. McGraw Hill, NY.
- Kawato, M., Furukawa, K., Suzuki, R. (1987). 'A hierarchical neural-network model for control and learning of voluntary movement'. *Biol. Cybern.* 57: 169-185.
- Kohonen, T (1990). 'The self-organizing map'. *Proc. IEEE*, 78: 1464-1480.
- Kohonen, T. (1988). 'The "Neural" phonetic typewriter'. *IEEE Computer*, Março, pp 11-22.
- Komi, P.V. (1973). 'Relationship between muscle tension, EMG, and velocity of contraction under concentric and eccentric work'. In *New Developments in EMG and clinical neurophysiology*, (ed.) Desmedt, J.E. S. Karger, Basel, pp. 595-606.
- Komi, P.V., Viitasalo, J.T., Rauramaa, R., Vichko, V. (1978). 'Effect of isometric strength training on mechanical, electrical, metabolic aspects of muscle function'. *Eur. J. Physiol.*, 40: 45-55.
- Kordas, M (1969). 'The effect of membrane polarization on the time course of the end-plate current in frog sartorius muscle'. *J. Physiol.* , 204: 493-502.
- Kuffler, S.W. (1942). 'Electrical potential changes in an isolated nerve-muscle junction'. *J. Neurophysiol.*, 5: 18-26.
- Kuroda, E., Klissouras, V., Milsum, J. (1970). 'Electrical and metabolic activities and fatigue in human isometric contraction'. *J. Appl. Physiol.*, 29: 358-367.
- Le Cun, Y (1985). 'Une procedure d'apprentissage pour reseau a seuil assymetrique'. *Proceedings of Cognitiva '85*, Paris, 599-604.
- Leontaritis, I.J., Billings, S.A. (1987). 'Model selection and validation methods for nonlinear systems'. *Int. J. Control*, 45: 311-341.
- Liberson, W.T., Holmquest, H.J., Scot, D., Dow, M.(1961). 'Functional eletrotherapy: Stimulation of the peroneal nerve synchronized with the swing phase of the gait of hemiplegic patients'. *Arch. Phys. Med. Rehabil.*, 42: 101-105.
- Lippmann, R.P. (1987). 'An introduction to computing with neural nets'. *IEEE ASSP Mag.*, Abril, pp 4-22.

Lippold, O.C.J. (1952). 'The relation between integrated action potentials in a human muscle and its isometric tension'. *J. Physiol.*, 117: 492-499.

Lukert, B (1982). 'Osteoporosis -- a review and update'. *Arch. Phys. Med. Rehabil.* 63: 480-484.

Marsolais, E.B., Kobetic, R. (1987). 'Functional electrical stimulation for walking in paraplegia'. *J. Bone and Joint Surg.*, 69A: 728-733.

McClelland, M., Andrews, B.J., Patrick, J.H., Freeman, P.A., El Masri, W.S. (1987). 'Augmentation of the Oswestry parawalker orthosis by means of surface electrical stimulation: gait analysis of three patients'. *Paraplegia*, 25: 32-38.

McClelland, J.L., Rumelhart, D.E., o PDP Research Group (1988). '*Parallel distributed processing: Explorations in the microstructure of cognition*', Vol. 2, 'Psychological and biological models'. The MIT Press, Cambridge, MA.

McCulloch, W.S., Pitts, W. (1943). 'A logical calculus of the ideas immanent in nervous activity'. *Bull. Math. Biophys.*, 5: 115-133.

McGregor, D.R., Odetayo, M.O., Dasgupta, D. (1992). 'Adaptive control of a dynamic system using genetic-based methods'. *Proc. IEEE Symp. Intelligent Control*, Glasgow, pp 521-525.

Miller, W.T, Sutton, R.S., Werbos, P.J. (eds.) (1990). '*Neural networks for control*'. The MIT Press, Cambridge, MA.

Milner-Brown, B.S., Stein, R.B. (1975). 'The relation between the surface electromyograph and muscular force'. *J. Physiol.*, 246: 549-569.

Minsky, M, Papert, S. (1969). '*Perceptrons*'. The MIT Press, Cambridge, MA.

Monzingo, R.A., Miller, W.T. (1980). '*Introduction to adaptive arrays*'. John Wiley & Sons, NY.

Moritany, T., de Vries, H.A. (1978). 'Re-examination of relationship between the surface integrated EMG and force in isometric contraction'. *Am. J. Phys. Med.*, 57: 263-271.

Nasrabadi, N.M., Feng, Y (1988). 'Vector quantisation of images based upon the Kohonen Self-Organizing Feature Maps'. *Proc. IEEE Conf. Neural Networks*, San Diego, 1: 101-108.

Nene, A.V. (1989). 'An assessment of the ORLAU parawalker-electrical stimulation powered orthosis'. *Proc. IEEE EMBS 11th Annual Conf.*, Seattle, pp 1016-1017.

Olney, S.J., Winter, D.J. (1985). 'Predictions of knee and ankle moments of force in walking from EMG and kinematic data'. *J. Biomech.*, 13: 361-368.

Onyshko, S., Winter, D.A. (1980). 'A mathematical model for the dynamics of human locomotion'. *J. Biomech.*, 13: 361-368.

Pandy, M.G., Berme, N. (1988a). 'A numerical method for simulating the dynamics of human walking'. *J. Biomech.*, 21: 1043-1052.

Pandy, M.G., Berme, N. (1988b). 'Synthesis of human walking: A planar model for single support'. *J. Biomech.*, 21: 1053-1060.

- Parker, D.B. (1982). *'Learning Logic'* (TR-47). Center for Computational Research in Economics and Management Science. MIT, Cambridge, MA.
- Peckham, P.H., Keith, M.W. (1992). 'Motor prostheses for restoration of upper extremity function'. In *'Neural prosthesis: Replacing motor function after disease or disability'*, cap. 8, (ed.) Stein, B.R., Peckham, P.H., Popovic, D.P. Oxford University Press, Oxford.
- Pedotti, A. (1977). 'A study of motor coordination and neuromuscular activities in human locomotion'. *Biol. Cybern.*, 26: 53-62.
- Penrose, R. (1989). *'The Emperor's new mind'*. Oxford University Press, NY.
- Perry, J. (1981). 'Rehabilitation of spasticity'. In *'Spasticity, disordered motor control'*, (ed.) Feldman, R.G., Young, R.R., Koella, W.P. New Book Medical Publishers, Chicago.
- Petrofsky, J.S., Philips, C.A., Heaton, H.H. (1984). 'Feedback control system for walking in man'. *Comput. Biol. Med.*, 14: 135-149.
- Philips, C.A. (1991). *'Functional electrical rehabilitation: Technological restoration after spinal cord injury'*. Springer-Verlag, NY.
- Philips, C.A., Petrofsky, J.S., Hendershot, D.M., Stafford, D. (1984). 'Functional electrical exercise -- a comprehensive approach for physical conditioning of the spinal cord injured patient'. *Orthopedics* 7: 1112-1114.
- Popovic, D. (1992). 'Functional electrical stimulation for lower extremities'. In *'Neural prosthesis: Replacing motor function after disease or disability'*, cap. 11, (ed.) Stein, B.R., Peckham, P.H., Popovic, D.P. Oxford University Press, Oxford.
- Popovic, D. (1990). 'Dynamics of a self-fitting modular orthosis'. *IEEE J. Robotics Automation*, 6: 200-207.
- Popovic, D., Tomovic, R., Schwirtlich, L. (1989), 'Hybrid assistive system - the motor neuroprosthesis'. *IEEE Trans. Biomed. Eng.*, 36: 729-736.
- Purves, D. (1988). *'Body and brain: A trophic theory of neural connections'*. Harvard University Press, MA.
- Purves, D., Thompson, W.J., Yip, J.W. (1981). 'Reinervation of ganglia transplanted to the neck from different levels of the guinea pig sympathetic chain'. *J. Physiol.* 313: 49-63.
- Rall, W. (1969). 'Time constants and electronic length of membrane cylinders and neurons'. *Biophys. J.*, 9: 1483-1508.
- Rall, W. (1960). 'Membrane potential transients and membrane time constant of motoneurons'. *Expl. Neurol.*, 2: 503-532.
- Renders, J.M., Hanus, R. (1992). 'Biological learning metaphors adaptive process control'. *Proc. IEEE Symp. Intelligent Control*, Glasgow, pp 469-474.

- Ritter, H.J., Martinetz, T.M., Schulten, K.J. (1989). 'Topology conserving maps for learning visuo-motor coordination'. *Neural Networks*, 2: 159-168.
- Rose, G.K. (1979). 'The principles and practice of hip guidance articulations'. *Prosthetics and Orthotics Intl.*, 3: 37-43.
- Rosenblatt, F. (1958). 'The perceptron: A probabilistic model for information storage and organization in the brain'. *Psychol. Rev.*, 65: 386-408.
- Rosenblatt, F. (1962). '*Principles of neurodynamics*'. Spartan Books, Washington, DC.
- Rowley, D.I., Edwards, J. (1987). 'Helping the paraplegic to walk'. *J. Bone and Joint Surg.*, 69: 173-174.
- Rudin, L.N., Levine, L. (1951). 'Bilateral compression of the radial nerve'. *Physical Ther.* *Rev.*, 31: 229-231.
- Rumelhart, D.E., McClelland, D.L., o PDP Research Group (1986a). '*Parallel Distributed Processing*', Vol. 1. The MIT Press, Cambridge, MA.
- Rumelhart D.E, Hinton, G.E., Williams, R.J. (1986b). 'Learning representations by backpropagation errors'. *Nature*, 323: 533-536.
- Rushton, D.N. (1990). 'Choice of nerves or roots for multichannel leg-controller implant. In (ed.) Popovic, D.B., '*Advances in external control of human extremities X*', pp 23-32. Nauka, Belgrado.
- Santini, M. (ed.) (1975). '*Golgi Centennial Symposium*'. Raven Press, NY.
- Schoenberg, A., Long, J. (1987). 'Design of a quickly-assembled, light-weight leg orthosis for FES assisted paraplegic mobility'. *Proc. RESNA 10th Annual Conf.*, San Jose, CA, pp 633-635.
- Scruton, D.R. (1971). 'A reciprocating brace with poly-planar hip hinges used on spina bifida children'. *Physiotherapy*, 57: 61-66.
- Seireg, A., Arvikar, R.J. (1973). 'A mathematical model for evaluation of forces in the lower extremities of the musculoskeletal system'. *J. Biomech.*, 6: 313-326.
- Sepulveda, F., Wells, D.M., Vaughan, C.L. (1993). 'A neural network representation of electromyography and joint dynamics in human gait'. *J. Biomech.* 26: 101-109.
- Shepanski, J.F., Macy, S.A. (1987). 'Teaching artificial neural systems to drive: Manual training techniques for autonomous systems'. *Proc. 1987 Neural Information Processing Systems Conf.*, (ed.) Anderson, D.Z., American Institute of Physics, NY, pp 693-700.
- Shepherd, G.M. (1988). '*Neurobiology*'. Oxford University Press, NY.
- Sholl, D.A. (1956). '*The organization of the cerebral cortex*'. Methuen Press, London.
- Siegler, S., Seliktar, R., Hyman, W. (1982). 'Simulation of human gait with the aid of a simple mechanical model'. *J. Biomech.*, 15: 415-425.

- Solomonow, M. (1992). 'Biomechanics and physiology of a practical functional neuromuscular stimulation powered walking orthosis for paraplegics'. In *Neural prosthesis: Replacing motor function after disease or disability*, cap. 10, (ed.) Stein, B.R., Peckham, P.H., Popovic, D.P. Oxford University Press, Oxford.
- Solomonow, M., Baratta, R., Hirokawa, S., Rightor, N., Walker, W., Beaudette, P., Soji, H., D'Ambrosia, R. (1989). 'The RGO generation II: Muscle stimulation powered orthosis as a practical walking system for thoracic paraplegics. *Orthopedics*, 12: 1309-1315.
- Stallard, J., Major, R.E., Patrick, J.H. (1989). 'A review of the fundamental design problems of providing ambulation for paraplegic patients'. *Paraplegia*, 27: 70-75.
- Stallard, Sankarankutty, M., Rose, G.K. (1978). 'A comparison of axillary, elbow, and Canadian crutches'. *Rheum. Rehabil.*, 17: 237-239.
- Stein, R.B. (1992). 'Feedback control of normal and electrically induced movements'. In *Neural prosthesis: Replacing motor function after disease or disability*, cap. 13, (ed.) Stein, B.R., Peckham, P.H., Popovic, D.P. Oxford University Press, Oxford.
- Szeckely, G. (1968). 'Development of limb movements: Embriological, physiological, and model studies'. In *Ciba Foundation Symp. on Growth of Nervous System*, (ed.) Wolstenholme, G.E.W, O'Connor, M. Churchill, London, pp77-93
- Taga, G., Yamaguchi, Y., Shimizu, H. (1991). 'Self-organized control of bipedal locomotion by neural oscillators in unpredictable environment'. *Biol. Cybern.* 65: 147-159.
- Thoma, H., Frey, M., Hole, J., Kern, H., Mayrn, W, Schwanda, G., Stoerh, H. (1987). 'Functional neurostimulation to substitute locomotion in paraplegia patients. In (ed.) Andrade, J.D., *Artificial Organs*, pp 515-529. VCH Publishers Inc., NY.
- Tomovic, R., Vukobratovic, M., Vodovnik, L. (1972). 'Hybrid actuators for orthotic systems: Hybrid assistive devices'. *Proc. Advances in External Control of Human Extremities IV*, Dubrovnik, pp 73-79.
- Tuttle, R.H. (1990). 'The pitted pattern of Laetoli feet'. *Natural History*, 3: 60-65.
- Vaughan, C.L., Davis, B.L., O'Connor, J.C. (1992). *Dynamics of human gait*. Human Kinetic Publishers, IL.
- Vrendenbregt, J., Rau, G. (1973). 'Surface electromyography in relation to force, muscle length, and endurance'. In *New Developments in EMG and clinical neurophysiology*, (ed.) Desmedt, J.E. S. Karger, Basel, pp. 607-622.
- Wang, H., Lee, T.T., Gruver, W.A. (1992). 'A neuromorphic controller for a three-link biped robot'. *IEEE Trans. Sys. Man and Cybern.*, 22: 164-169.
- Werbos, P.J. (1990). 'Backpropagation through time: What it does and how to do it'. *Proc. IEEE*, 78: 1550-1560.
- Werbos, P.J. (1974). *Beyond regression: New tools for prediction and analysis in the behavioral sciences*. Tese de doutorado, Harvard University, Cambridge, MA.

- Wetzel, M.C., Stuart, D.G. (1976). 'Ensemble characteristics of cat locomotion and its neural control'. *Prog. Neurobiol.* 7: 1-98.
- Widrow, B. (1987). 'The original adaptive neural net broom-balancer'. *Proc. IEEE Int. Symp. Circuits and Systems*, pp 351-357.
- Widrow, B. Smith, F.W. (1963). 'Pattern recognition control systems'. *Computer and Information Sciences Symposium Proceedings*. Spartan Books, Washington, DC.
- Widrow, B, Stearns, S.D. (1985). '*Adaptive signal processing*'. Prentice Hall, Englewood Cliffs, NJ.
- Winter, D. (1987). '*The biomechanics and motor control of human gait*'. University of Waterloo Press, Ontario.
- Winter, D.A. (1984). 'Biomechanics of human movement with applications to the study of human locomotion'. *CRC Crit. Rev. Biomed. Eng.*, 9: 287-314.
- Zhang, B., Grant, E. (1992). 'Using competitive learning for state space partitioning'. *Proc. IEEE Symp. Intelligent Control*, Glasgow, pp 391-396.
- Zahalak, G.J. (1992). 'An overview of muscle modeling'. In '*Neural prosthesis: Replacing motor function after disease or disability*', cap. 2, (ed.) Stein, B.R., Peckham, P.H., Popovic, D.P. Oxford University Press, Oxford.

APÊNDICE A

DIAGRAMA DA RETRO-PROPAGAÇÃO INSTANTÂNEA

- i = neurônio de entrada
- j = neurônio da camada escondida
- k = neurônio da camada de saída
- \mathcal{R} = taxa de aprendizado
- $u = \sum_j (w_{j,k} \cdot Op_j) + bias_k$

