

# CONTROLE DE UM MANIPULADOR BI-ARTICULADO COM UMA REDE NEURAL DE CONTATOS MULTI-SINÁPTICOS

Benedito Dias Baptista Filho<sup>(†)</sup> e Eduardo Lobo Lustosa Cabral<sup>(††)</sup>

<sup>(†)</sup> Divisão de Termo-Hidráulica – IPEN-CNEN/SP - Travessa R, 400 - Cidade Universitária

<sup>(††)</sup> Depto de Engenharia Mecânica – Escola Politécnica da USP - Av. Prof. Mello Moraes, 2231  
CEP 05508-900 – São Paulo - SP

**Resumo** Este trabalho apresenta uma nova concepção de redes neurais artificiais para aplicação em controle de sistemas dinâmicos. Este novo conceito de rede neural artificial é baseado em um modelo de neurônio com múltiplas sinapses. As forças de ligação das sinapses são modificadas por meio de um processo seletivo e cumulativo, seguindo um método de aprendizado não supervisionado. Esta nova rede é aplicada no controle de posição de um manipulador bi-articulado no plano, mostrando resultados excelentes.

**Palavras Chaves:** Arquitetura de redes neurais, sistemas de controle, controle de posição de robôs manipuladores.

**Abstract:** This work presents the position control of a robot manipulator using a new artificial neural network. This neural network is based on a new neuron model with multiple synapses. The synapses' connective strengths are modified through a selective and cumulative process that resembles an unsupervised learning method. These new concepts applied to the position control of the planar two-link manipulator show excellent results.

**Keywords:** Neural network architecture, Control systems, Manipulator position-control.

## 1 INTRODUÇÃO

O objetivo deste trabalho é apresentar os resultados de uma inovação no campo de redes neurais artificiais que pode ser utilizada no controle de braços robóticos. Esta nova rede neural é baseada no projeto de redes especializadas para uma determinada tarefa e na fisiologia de sistemas neuronais biológicos. Este trabalho consiste de seis seções. A primeira seção é esta introdução. A segunda seção descreve os novos conceitos introduzidos. A terceira seção apresenta a aplicação dos novos conceitos de redes neurais no controle do braço robótico. A quarta seção apresenta os resultados e sua discussão. A quinta seção é o resumo das principais conclusões.

## 2 OS NOVOS CONCEITOS

Os novos conceitos implementados em uma rede neural artificial utilizada no controle de posição de um manipulador bi-articulado no plano apresentado neste trabalho, foram desenvolvidos como parte de uma tese de doutorado conduzida

entre 1994 e 1998, com todos os conceitos detalhados em [1] e [2]. Esses novos conceitos foram baseados em circuitos e funções neuronais estudados na neurofisiologia. O livro de Kandel *et al* [3] é a referência utilizada para estas informações.

### A. Processo de Sinalização Neuronal

1) *Função de transferência neuronal:* A função de transferência de sinais nas unidades que representam os neurônios dentro desta nova rede neural é uma *tangente hiperbólica modificada*:

$$O = T_N \tanh\left(\alpha \sum S\right), \quad (1)$$

onde  $O$  é o sinal de saída,  $T_N$  representa o "tamanho" da unidade,  $\alpha$  é um ganho, e  $\sum S$  é a soma de todas as entradas sinápticas na unidade. O "tamanho" pode ser ajustado a valores convenientes para, por exemplo, melhorar a linearidade de resposta em uma determinada faixa de interesse, ou para amplificar ou atenuar a relação entrada/saída.

2) *Modelo de Transmissão Sináptica:* O processo de transmissão sináptica é simulado por um conjunto de funções que imitam uma curva Gauseana como a representada na Figura 1 e expressa como:

$$S = \frac{T}{1 + a(I - I_0)^2}, \quad (2)$$

onde,  $T$  é a "força de ligação" da sinapse, que pode assumir qualquer valor positivo (excitatória) ou qualquer valor negativo (inibitória),  $a$  é uma constante que pode ser escolhida adequadamente para produzir funções sem variações abruptas, de acordo com o número de terminais sinápticos,  $I$  é o valor do sinal transmitido no axônio, e,  $I_0$  é o valor de  $I$  que maximiza  $S$ , o valor de saída para a célula alvo. Esse valor  $I_0$  é chamado de "limiar".

A expressão (2), que representa um terminal sináptico isolado, permite amplificação e resposta seletiva. Essa função aprimora a função de transferência global do neurônio e é muito mais simples do que uma função sigmóide em termos de esforço. Com forças e limiares convenientes, um conjunto de funções da forma da Eq. (2) pode reproduzir qualquer tipo de função contínua.




Figura 1 – Função de Transferência Sináptica.

## B. Aprendizado e Mecanismos de Memória

Segundo Kandel *et al* [3] em circuitos neuronais biológicos, um dado conjunto de sinapses pode sofrer diferentes modificações em várias formas de aprendizado, por exemplo, podem ser deprimidas pela habituação ou podem ser reforçadas pela sensitização. Formas de aprendizado mais complexas são o condicionamento clássico e a prática. Os processos envolvidos no mecanismo de memória reflexiva sugerem o desenvolvimento de um circuito especial para implementar um processo de aprendizado. Esse circuito, mostrado na Fig. 2, aproveita um sinal de erro que, por meio de um interneurônio facilitador, é conectado aos terminais pré-sinápticos da unidade de saída em ligações tipo "axo-axônicas" (ligações de sinapses diretamente nos terminais sinápticos de um axônio). É nesses terminais que as mudanças plásticas, características do aprendizado, são efetivadas. O sinal (+/-) do impulso dependente do erro é quem decide se o processo corresponde a uma *facilitação* ou *inibição pré-sináptica*, o que irá *aumentar* ou *reduzir* a força de ligação sináptica.

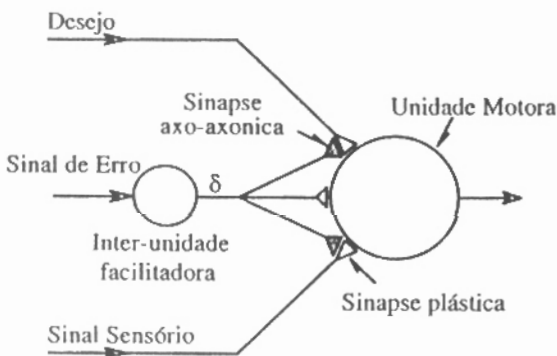


Figura 2 – Sinapses para o processo de aprendizado.

A alteração na força de transmissão sináptica devido ao processo de aprendizado é reproduzida por um modelo de plasticidade baseado em mecanismos de armazenamento de memória. Isso é feito por um processo cumulativo onde o termo governante é proporcional ao sinal de entrada (o sinal de treinamento  $\delta$ ) e à sua taxa de decaimento, de acordo com a seguinte expressão:

$$\frac{dC}{dt} = T_c \delta - \lambda C, \quad (3)$$

onde  $C$  é o fator de disparo de mudanças de longo-termo,  $\delta$  é o sinal de saída da inter-unidade facilitadora,  $\lambda$  é uma constante de decaimento, e,  $T_c$  é a força de ligação da sinapse facilitadora (que controla a taxa de mudança).

De acordo com a Eq. (3), o fator de disparo de mudanças de longo-termo ( $C$ ) pode crescer a uma taxa proporcional ao sinal de aprendizado ( $\delta$ ) até um valor de equilíbrio. Isso acelera ou desacelera as mudanças sinápticas. Se o sinal que chega decresce a zero, o fator de disparo de mudanças de longo-termo também cai a zero, de acordo com uma taxa estabelecida pela constante de decaimento ( $\lambda$ ). Isso significa que, após um razoável período de treinamento, quando não existir mais um sinal de erro e nem excessivas mudanças dinâmicas, não haverá mais necessidade de mudanças, tornando assim o processo inerentemente estável.

Para completar essa idéia é necessário ainda um artifício para que as mudanças se concentrem nos terminais sinápticos convenientes, isto é, naqueles em que o valor do limiar ( $I_0$ ) é mais próximo do valor do sinal do desejo. Essa característica inédita irá, além de promover a seleção adequada do terminal sináptico, estabelecer a taxa de mudança da força de ligação ( $T$ ) como função do fator de disparo de mudanças de longo-termo e do limiar sináptico. Isso é implementado pela seguinte expressão:

$$\frac{dT_j}{dt} = \frac{C}{1 + a_s(I - I_{0j})^2}, \quad (4)$$

onde  $T_j$  é a força de ligação da  $j$ -ésima sinapse da unidade motora,  $a_s$  é a constante da função da sinapse facilitadora,  $I$  é o valor do sinal proveniente do nível de controle superior (o desejo), e  $I_{0j}$  é o limiar da sinapse.

## C. Arquitetura da Unidade de Controle Motor

O conceito da estrutura principal da rede neural está representado na Fig. 3. Ele define uma "unidade de controle motor," representando os novos conceitos aplicados ao propósito de controle.

Para dispensar a necessidade de alimentar a rede com medidas das taxas de variação dos sinais do processo, foi utilizado um artifício que consiste na medida da diferença de sinais de unidades em camadas consecutivas, portanto defasados no tempo. As inter-unidades responsáveis por essa função são ligadas por conexões "rígidas" (sem plasticidade). Os sinais de saída dessas unidades representam as taxas de mudança dos sinais sensorios que, combinados com o sinal de erro em uma unidade intermediária, por sua vez conectada à unidade de saída, representam a dinâmica do sistema em uma analogia à soma de  $a_0\epsilon + a_1d\epsilon/dt + a_2d^2\epsilon/dt^2 + \dots$ . O coeficiente  $a_0$  do erro é implementado por funções sinápticas que resultam em uma função de transferência linear, da seguinte forma:

$$S_{out} = \frac{1}{N} \left( \frac{T_c}{1 + 0.25(I - 2)^2} \right); \quad (7)$$

$$S_{\text{er}} = \frac{1}{N} \left( \frac{-T_e}{1 + 0.25(I + 2)^2} \right); \quad (8)$$

onde  $T_e$  é força de ligação das sinapses de erro.

A funções de transferência sináptica nas conexões dos sinais de taxas de variação com a inter-unidade são modeladas com características de amortecimento do tipo  $\lambda|x|$ . Isso é necessário para atenuar oscilações e tornar o processo estável mesmo na presença de altas taxas de variação. Esse amortecimento é

encontrado em sistemas biológicos tanto em circuitos de neurônios quanto em células musculares. Assim, tem-se:

$$S_{\text{ux}} = \frac{1}{N} \left( \frac{T_r}{1 + 11(I - 1)^2} \right); \quad (9)$$

$$S_{\text{ur}} = \frac{1}{N} \left( \frac{-T_r}{1 + 11(I + 1)^2} \right); \quad (10)$$

onde  $T_r$  é a força de ligação das sinapses de mudanças.




Figura 3 – Conceito de Unidade de Controle Motor.

Os sinais do sistema sensorio e do nível de controle superior são transmitidos através de dois conjuntos de sinapses, simétricas em termos de limiar e força de ligação. Essas sinapses possuem características plásticas e são ajustadas pelo aprendizado. O comportamento dessas sinapses é representado por:

$$S_j = \frac{T_j}{1 + a(I_c - I_{0,j})^2}; \quad (11)$$

$$S_k = \frac{T_k}{1 + a(I_i - I_{0,k})^2}; \quad (12)$$

onde  $T_{j(k)}$  é a força de ligação da  $j(k)$ -ésima sinapse.

Antes de qualquer treinamento essas sinapses “não têm força”, i.e.,  $T_{j(k)} = 0$ . O surgimento de um sinal de erro  $\epsilon$  gera um sinal  $\delta$  diferente de zero que age no sentido de aumentar ou diminuir o fator de disparo de longo-termo  $C$ , da Eq. (3). As mudanças plásticas, responsáveis pelo processo de aprendizado, tomam então lugar nas sinapses da unidade motora. O sinal do “desejo” é utilizado para ajustar todas as sinapses plásticas, mesmo aquelas do caminho que vem do sistema sensorio. Uma descrição detalhada dessa unidade de controle motor se encontra nas referências [1] e [2].

### 3 MODELAGEM DO PROBLEMA

Esse conceito de Unidade de Controle Motor é aplicado no controle de posição de um manipulador bi-articulado no plano.

A verificação do desempenho da rede, em termos de controle e habilidade de aprendizado, para alcançar alvos desejados, é realizada através de simulações.

#### A. Modelo da Dinâmica do Processo

O manipulador bi-articulado é um problema não-linear com dois graus de liberdade. As variáveis consideradas no modelo são mostradas na Fig. 4. A dinâmica desse sistema é representada por:

$$\tau_1 = H_{11}\ddot{\theta}_1 + H_{12}\ddot{\theta}_2 + h_{122}\dot{\theta}_2^2 + h_{111}\dot{\theta}_1\dot{\theta}_2 + G_1; \quad (13)$$

$$\tau_2 = H_{22}\ddot{\theta}_2 + H_{12}\ddot{\theta}_1 + h_{211}\dot{\theta}_1^2 + G_2; \quad (14)$$

onde  $\theta_1$  é o ângulo entre o primeiro segmento e o eixo-x,  $\theta_2$  é o ângulo entre o segundo e o primeiro segmentos,  $\tau_1$  e  $\tau_2$  são os torques nas articulações 1 e 2 respectivamente, e os outros termos são definidos a seguir.

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

$$H_{12} = m_2 l_1 l_{c2} \cos \theta_2 + m_2 l_{c2}^2 + I_2;$$

$$H_{22} = m_2 l_{c2}^2 + I_2;$$

$$h_{122} = -m_2 l_1 l_{c2} \sin \theta_2;$$

$$h_{111} = -2m_2 l_1 l_{c2} \sin \theta_2;$$

$$h_{211} = m_2 l_1 l_{c2} \sin \theta_2;$$

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

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

Os subscritos 1 e 2 se referem ao  $i$ -ésimo segmento do manipulador com massa  $m_i$ , comprimento total  $l_i$ , distância da articulação ao centro de massa  $l_{ci}$  e momento de inércia  $I_i$ , e  $g$  é a aceleração da gravidade.

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

$$J_M \frac{dn}{dt} = \tau_M - \tau - \tau_{PM}, \quad (15)$$

onde  $J_M$  é o momento polar de inércia do rotor,  $n$  é a rotação,  $\tau_M$  é o torque motor,  $\tau_{PM}$  é o torque de perdas, e  $\tau$  é o torque de carga dado pelas Eq. (13) ou (14).




Figura 4 – Modelo do Manipulador bi-articulado.

O torque motor é dado por:

$$\tau_M = K_T O, \quad (16)$$

onde  $K_T$  é o ganho motor/atuador, e  $O$  é o sinal de saída do controlador neural acoplado. O torque de perdas,  $\tau_{PM}$ , é composto de duas partes: perdas nos mancais ( $\tau_{LB}$ ) e perdas no motor ( $\tau_{LM}$ ). Para descrever as perdas nos mancais, foram considerados o atrito estático e atrito viscoso:

$$\tau_{LB} = K_{LB} \mu, \quad (17)$$

onde  $K_{LB}$  é uma constante proporcional à pressão de contato, e  $\mu$  é o fator de atrito. Esse torque foi correlacionado a partir de dados obtidos na referência [4].

Assume-se que o torque de perdas no motor é proporcional ao quadrado da rotação, ou seja:

$$\tau_{LM} = K_{LM} \omega^2, \quad (18)$$

onde  $K_{LM}$  é uma constante, função do tipo do motor.

#### B. Controle de Posição com a Nova Rede Neural

Como no processo do manipulador bi-articulado existem dois atuadores, devem ser utilizadas pelo menos duas unidades de controle. Para o propósito de demonstração os sinais de entrada destas duas unidades é restringido apenas aos ângulos,  $\theta_1$  e  $\theta_2$ , desejados e atuais. Observe que as velocidades angulares não são necessárias porque o sistema possui inter-unidades para estimar as taxas de variação dos ângulos. Note-se ainda que nesta demonstração a posição da extremidade do manipulador é tratada como um resultado e não como um objetivo. Isso é feito para evitar a necessidade de outras camadas para converter posição da extremidade em ângulos desejados.

A Figura 5 mostra a rede que representa os dois controladores acoplados ao processo. Considerando que a posição do segundo segmento afeta a carga no primeiro, o atuador do primeiro motor deve ser alimentado com a soma das saídas dos dois controladores. Levando em conta que o ângulo  $\theta_2$  é

relativo à direção do primeiro segmento,  $\theta_1$  e  $\theta_2$  são somadas para alimentar o segundo controlador. É importante destacar que um sistema diferente poderia ser modelado.

Na Figura 5,  $\theta_{1D}$  e  $\theta_{2D}$  representam os comandos de posição desejada,  $O_1$  e  $O_2$  são os sinais de saída das unidades de controle motor que irão alimentar os atuadores,  $D_1$  e  $D_2$ .  $I_1$  e  $I_2$  são as inter-unidades responsáveis pela avaliação dos erros  $IN^{R1}$  e  $IN^{R2}$  são as inter-unidades responsáveis pela avaliação da primeira derivada das taxas de variação (neste problema não são necessárias ordens mais elevadas),  $IN^F$  são as inter-unidades facilitadoras do aprendizado, e  $IN^D$  são as inter-unidades usadas para gerar os sinais necessários para avaliar as taxas de mudança dos sinais. Observa-se que inter-unidades de entrada,  $IN^I$ , foram acrescentadas para desempenhar a função de soma de entradas. Nota-se ainda que os caminhos de sistema sensorio são representados por linhas pontilhadas enquanto que as linhas sólidas representam os sinais do nível superior de controle e os caminhos intermediários.

Deve-se notar que, nesta implementação, as sinapses plásticas aprendem somente o torque gravitacional. Outras implementações podem ser desenvolvidas para a rede aprender os torques gerados pelas forças centrífugas e Coriolis.

Os parâmetros de simulação, o processo de treinamento e avaliação de desempenho são apresentados e discutidos na próxima seção.

## 4 RESULTADOS E DISCUSSÃO

A Tabela 1 apresenta os parâmetros numéricos utilizados para simular o manipulador bi-articulado da Fig. 5. Os principais parâmetros dos componentes da rede neural são dados na Tabela 2.

O treinamento é desempenhado "on-line", i.e., durante a execução de comandos de posição desejada. A mudança de comandos de "desejo", de acordo com a seqüência apresentada na Fig. 6, desenvolve o processo de aprendizado não supervisionado. Um conjunto de 28 posições alvo é usado no treinamento. O manipulador parte da posição de repouso,  $-90^\circ$  totalmente estirado, segue no sentido horário para a posição  $+185^\circ$ , retorna para a posição de repouso, segue no sentido anti-horário para a posição  $+185^\circ$ , retornando novamente para a posição de repouso. Esse conjunto de alvos é submetido à rede por seis vezes. A duração de cada busca ao alvo,  $t$ , em cada tentativa segue o seguinte: primeira e segunda tentativas,  $t = 5$  s.; terceira e quarta,  $t = 10$  s.; e, quinta e sexta,  $t = 20$  s.

O treinamento é desempenhado "on-line", i.e., durante a execução de comandos de posição desejada. A mudança de comandos de "desejo", de acordo com a seqüência apresentada na Fig. 6, desenvolve o processo de aprendizado não-supervisionado. Um conjunto de 28 posições alvo é usado no treinamento. O manipulador parte da posição de repouso,  $-90^\circ$ , totalmente estirado, segue no sentido horário para a posição  $+185^\circ$ , retorna para a posição de repouso, segue no sentido anti-horário para a posição  $+185^\circ$ , retornando novamente para a posição de repouso. Esse conjunto de alvos é submetido à rede por seis vezes. A duração de cada busca ao alvo,  $t$ , em cada tentativa segue o seguinte: primeira e segunda tentativas,  $t = 5$  s.; terceira e quarta,  $t = 10$  s.; e, quinta e sexta,  $t = 20$  s.




Figura 5 – Esquema simplificado da rede para o controle do manipulador.

Tabela 1 – Parâmetros para o modelo do Manipulador

Parâmetro	Segmento	
	1	2
Comprimento - $L$ (mm)	707	707
Massa - $m$ (kg)	3.0	2.0
Momento de Inércia - $I$ ( $\text{kg m}^2$ )	0.041	0.027
Ganho de Torque Motor - $K_T$ (N M)	60	30
Momento de inércia do rotor - $J_M$ ( $\text{kg m}^2$ )	0.0013	0.0013
Constante de perdas nos mancais - $K_{LB}$	1.0	1.0
Constante de perdas no Motor - $K_{LM}$	25.1	25.1

Tabela 2 - Parâmetros para a Rede Neural

Parâmetro	Valor
Tamanho das unidades - $T_N$ (Eq. 1)	2.1
Constante de ganho das unidades - $\alpha$ (Eq. 1)	0.5
Constante das sinapses plásticas - $a$ (Eq. 5, 6)	28.8
Número de sinapses plásticas - caminho sensorio	15
Número de sinapses plásticas - caminho "desejo"	15
Intervalo de limiares consecutivos ( $I_{0,j} - I_{0,j+1}$ )	0.1667
Força das sinapses de erro - $T_e$ (Eqs. 7, 8)	2.5
Força das sinapses de taxas - $T_r$ (Eqs. 9, 10)	0.09
Força das sinapses de facilitação - $T_c$ (Eq. 3)	0.1
Constante de decaimento - $\lambda$ (Eq. 3)	10.0
Constante de plasticidade sináptica - $a_s$ (Eq. 4)	144.0

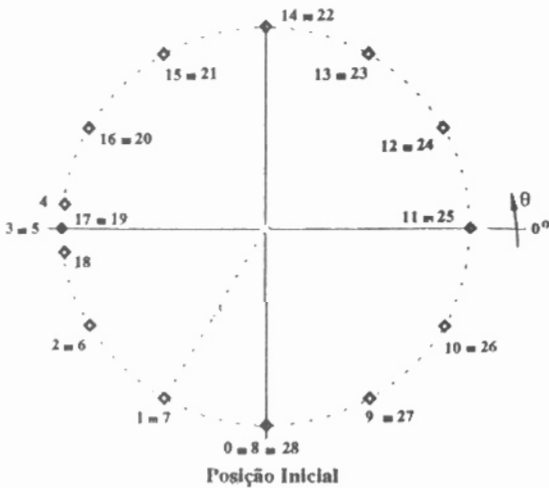


Figura 6 – Conjunto de posições para treinamento.

Após repetir o conjunto de comandos de treinamento por seis vezes, o sistema é capaz de atingir qualquer posição com razoável precisão e as forças de ligação dos dois conjuntos de sinapses plásticas, que eram inicialmente zero, cresceram para os valores mostrados na Figura 7. Essa fase de treinamento durou 1960 segundos de tempo simulado (com somente 85

segundos de CPU em um Microcomputador Pentium 166 MHz). Esta rapidez pode indicar que o processo de aprendizado é computacionalmente eficiente.

Após o treinamento, o próximo passo é verificar a resposta do sistema a qualquer outra entrada. Para isso o modelo de plasticidade foi bloqueado (fazendo  $T_c = 0$  na Eq. 3) para evitar novas atualizações nas forças de ligação e possibilitar a observação da capacidade de generalização. Foram executados testes sobre todo o domínio de  $\theta_{1D}$  e  $\theta_{2D}$  obtendo-se excelentes resultados. Também foram realizados testes sem bloquear o modelo de plasticidade, permitindo observar seu desempenho estável.

A Figura 8 exibe os resultados de um desses testes, mostrando a trajetória da extremidade do manipulador na busca de cinco alvos, cada um definido por um desejo diferente, mantido constante durante um período de 6 segundos. Esse exemplo contém duas posições presentes no conjunto de treinamento (pontos 2 e 4) e três posições não presentes no treinamento (pontos 3, 5 e 6). O último alvo é posicionado a uma grande distância da posição anterior para observar a estabilidade da rede na presença de grandes erros e altas velocidades. A evolução da distância da extremidade do manipulador ao alvo é

apresentada na Fig. 9, que mostra cinco picos que representam a transição entre cada comando. Observe-se que alvos, mesmo distantes mais do que 2000mm da posição corrente, são atingidos quase que sem oscilação em menos do que 5 segundos. Neste exemplo em que as unidades de controle motor possuem apenas 15 sinapses por lado, com um total de 60 contatos plásticos nas duas unidades, com somente 28 pontos de treinamento e 70 segundos de treinamento para cada ponto, o máximo erro em distância é menor do que 5mm.




Figura 7 – Forças de ligação sinápticas após treino.




Figura 8 – Trajetória da extremidade do manipulador.




Figura 9 – Distância da extremidade ao alvo.

## 5 CONCLUSÕES

O novo conceito de rede neural proposto para o controle de posição do manipulador bi-articulado no plano demonstra que a opção de se desenvolver redes especializadas para uma determinada tarefa parece ser muito promissor para soluções de controle.

O uso de múltiplos contatos sinápticos em cada terminação aumenta a capacidade de integração de cada unidade (neurônio). O uso de funções de transferência sináptica de classes mais elevadas do que a simples multiplicação de um peso melhora a relação entrada/saída permitindo a redução do número total de unidades com funções sigmóide que são mais demandantes em termos computacionais.

Este novo conceito de rede neural implementa mecanismos artificiais que imitam os mecanismos de habituação e sensitização observados em organismos vivos. O uso de um modelo simplificado de plasticidade nas sinapses permite aprendizado em tempo real durante o funcionamento do processo e sem a existência de algoritmos matemáticos não explicáveis fisicamente.

A tarefa de treinamento pode ser desempenhada "on-line", isto é, durante a execução de comandos desejados, de acordo com um método de aprendizado não-supervisionado. O limitado tempo de treinamento e o pequeno número de alvos necessários para o aprendizado, associados ainda com os bons resultados obtidos na tarefa de posicionamento em todo o domínio, mostra uma notável capacidade de generalização.

Esta nova rede neural é mais complexa do que as redes multicamada convencionais com retro-propagação do erro, em termos de arranjo de sinapses e funções de transferência, mas tem a vantagem de reduzir o número total de unidades necessárias. Como as funções de transferência das unidades (neurônios) é mais complexa do que as funções das sinapses, há um ganho líquido em termos de desempenho como demonstrado na seção 4. O desempenho no aprendizado mostrado no exemplo prevê que este é certamente um conceito promissor.

## REFERÊNCIA BIBLIOGRÁFICA

- Baptista F., B.D., Cabral, E.L.L., Soares, A.J. (1998). A New Approach to Artificial Neural Networks, *IEEE Transactions on Neural Networks*, Vol. 9, No. 6, pp. 1167-1179.
- Baptista F., B.D. (1998), *Redes Neurais para Controle de Sistemas de Reatores*, São Paulo: Tese de Doutorado – Instituto de Pesquisas Energéticas e Nucleares - IPEN-CNEN/SP.
- E.R. Kandel, J.H. Schwartz and T.M. Jessel, (1991) *Principles of Neural Science*, Prentice-Hall International Inc., Third Edition.
- Niemann, G., (1950) *Maschinenelemente*, Springer-Verlag OHG.