

Um Novo Conceito de Redes Neurais Artificiais para Controle de Sistemas de Reatores Nucleares

Benedito Dias Baptista Filho¹, Eduardo Lobo Lustosa Cabral²

¹Instituto de Pesquisas Energéticas e Nucleares

²Escola Politécnica da Universidade de São Paulo

E-mails: bdbfilho@net.ipen.br, elcabral@usp.br

Abstract

The novel approach to artificial neural networks based on a neuron model with multiple synapses developed by Baptista, Cabral and Soares (1998) is extended to accommodate external perturbations. This new development is applied to control the fluid temperature in a natural circulation loop. The learning and the action processes are made through simulations. The results show that besides the excellent learning capability and generalization, the new improvements are suitable to accommodate external perturbations so that the network is able to maintain the controlled variable within allowable limits even in the presence of strong perturbations.

1. Introdução

Neste trabalho são apresentados novos recursos adicionados ao novo conceito de redes neurais introduzido por Baptista, Cabral e Soares (1998). Essa nova classe de redes neurais, batizada de MULSY (**M**ultiple **S**ynapses), foi inicialmente concebida para aplicações de controle e é baseada na fisiologia de sistemas neurais biológicos. A unidade básica de controle, desenvolvida por Baptista (1998), já foi utilizada em outros trabalhos (ver ref. [1] a [4]). Agora é apresentada uma melhoria para capacitá-la a lidar com perturbações externas. A nova unidade é utilizada no controle de temperatura de um circuito térmico operando em circulação natural, a Bancada de Circulação Natural (BCN), descrita em [5]. O problema de controle da BCN é não-linear e devido à grande constante de tempo do sistema apresenta alguma dificuldade de controle pois são necessárias várias horas após qualquer ação para o sistema atingir regime permanente, dificultando a antecipação de ações.

O trabalho está dividido em cinco seções. A primeira é esta introdução. A segunda resume os principais conceitos das redes MULSY. A terceira seção descreve a BCN. A quarta seção apresenta a aplicação da rede MULSY no controle de temperatura, considerando a interferência de parâmetros externos, como a temperatura da água de resfriamento e a abertura de uma válvula. Na última seção são resumidas as conclusões.

2. O Conceito de Redes MULSY

As redes neurais artificiais atuais (RNA) são baseadas em unidades de processamento simples e arrançadas de um modo regular. Essas unidades são interligadas por conexões simples, os pesos, que representam sinapses. Mesmo após diversos aperfeiçoamentos introduzidos no algoritmo de retro-propagação, um dos mais utilizados, nos últimos anos alguns pesquisadores têm focalizado nossa atenção nas limitações dessa aproximação. Kolen e Goel (1991) concluíram que os métodos atuais podem ser demasiadamente limitados para lidar com os problemas que se desejaria lidar com redes neurais. Eles propõem que o desenvolvimento de métodos especializados para cada tipo de tarefa possa aumentar o poder das redes neurais artificiais.

Baptista., Cabral e Soares (1998) desenvolveram uma rede batizada de MULSY, que foi baseada nos seguintes princípios: 1) o projeto de uma RNA deve ser baseado em sistemas biológicos que realizem tarefas semelhantes, para aproveitar os benefícios de sua natureza evolucionária; 2) a RNA deve representar o que conhece e o que é capaz de aprender, e ainda deve ter capacidade de generalização; 3) a RNA deve ser robusta à perda de informações, dados incorretos e falha de unidades; 4) a tarefa de aprendizado deve ser realizada em tempo real, enquanto desempenhando a sua função, e deve ser independente das condições iniciais; e, 5) os processos de aprendizado e ação devem ser computacionalmente eficientes sem que seja necessário limitar o poder das funções de transferência sináptica, que podem permitir a obtenção de classes superiores de relação entrada/saída.

A Figura 1 apresenta a "unidade de controle motor controle básica", na qual se baseia a rede MULSY. O caminho de entrada de um nível de controle hierarquicamente superior ("o Desejo" - x_D) e o caminho que vem do sistema sensorio ("a Condição Atual" - x) convergem para a unidade responsável pela percepção do erro atual (ϵ) e para a unidade motora de saída. Essa arquitetura e fluxo de sinais se baseia em circuitos neurais biológicos como descritos por Kandel, Schwartz e Jessel (1991) e analisado por Baptista (1998).

Para modelar a função biológica de um aglomerado de neurônios motores utiliza-se uma única unidade com função de transferência que emula circuitos agonistas e

antagonistas. Essa função é uma tangente hiperbólica modificada:

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

onde, O é o sinal de saída, T_N representa o "tamanho" da unidade, α é um ganho, e $\sum S$ é a soma de todas as entradas sinápticas. "T" pode ser ajustado a valores que aumentem a linearidade na faixa de interesse ou que ampliem ou reduzam a relação entrada/saída.

Os sinais são transmitidos às unidades neurais através de conexões (sinapses) modeladas pela seguinte expressão:

$$S = \frac{T}{1 + a(x - x_0)^2}, \quad (2)$$

onde, T (de tamanho), é a força de ligação da sinapse, que pode ser um valor real positivo (sinapse excitatória)

ou um valor real negativo (sinapse inibitória), a é uma constante escolhida de modo a produzir uma resposta contínua para um conjunto de conexões, x é o valor do sinal de entrada, ou seja, o sinal conduzido pelo axônio, e x_0 (que define um limiar) é o valor de x que maximiza a função S , valor de saída da sinapse para a célula alvo. Em termos de processamento, essa função é muito mais simples que a função de transferência das unidades e permite amplificação e resposta seletiva. Com "tamanhos" e limiares adequados, um conjunto dessas funções pode aproximar qualquer função contínua.

Os sinais do "desejo" e "condição atual" são ligados à unidade de percepção de erro por meio de conexões rígidas, que não sofrem adaptação durante o treinamento. Elas são modeladas de modo a que a unidade sensora do erro receba o sinal da condição atual com sinal oposto ao sinal do desejo, i.e., $\varepsilon = x_D - x$.




Figura 1: Unidade Básica de Controle Motor da Rede MULSY.

Os terminais múltiplos aumentam a confiabilidade, o que permite construir um sistema mais imune a falhas. Os modelos dos terminais sinápticos tipo S_{e+} , S_{e-} , S_{i+} e S_{i-} da Fig. 1, são baseados nas seguintes equações:

$$S_{e+} = \frac{1}{N} \left(\frac{2}{1 + 0.25(x - 2)^2} \right) \quad (3)$$

$$S_{e-} = \frac{1}{N} \left(\frac{2}{1 + 0.25(x + 2)^2} \right) \quad (4)$$

$$S_{i+} = \frac{1}{N} \left(\frac{-2}{1 + 0.25(x + 2)^2} \right) \quad (5)$$

$$S_{i-} = \frac{1}{N} \left(\frac{-2}{1 + 0.25(x - 2)^2} \right) \quad (6)$$

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

As taxas de mudança dos sinais sensoriais (derivadas no tempo) são avaliadas internamente à rede, por meio da diferença entre sinais percebidos por unidades em camadas consecutivas. As unidades responsáveis por essa função são representados na metade inferior da rede representada na Fig. 1. Essas unidades são acopladas por meio de conexões rígidas como aquelas utilizadas na unidade de erro. Os sinais de saída dessas unidades, nos vários níveis reproduzem as taxas de mudança dos sinais sensoriais, que é equivalente às taxas

de mudanças do erro quando o valor desejado é constante. Esses sinais são combinados ao sinal de erro em uma unidade intermediária que faz as conexões com a unidade motora de saída. Essa combinação de sinais representa a dinâmica do sistema analogamente ao que representa a equação:

$$f(\epsilon) = a_0\epsilon + a_1 \frac{d\epsilon}{dt} + \frac{d^2\epsilon}{dt^2} + \dots \quad (7)$$

O coeficiente do termo de erro, a_0 , é implementado pelas funções sinápticas dadas nas equações seguintes, que possuem constantes ajustadas para produzir uma função de transferência linear.

$$S_{eps} = \frac{1}{N} \left(\frac{T_\epsilon}{1 + 0.25(x-2)^2} \right) \quad (8)$$

$$S_{ips} = \frac{1}{N} \left(\frac{-T_\epsilon}{1 + 0.25(x+2)^2} \right) \quad (9)$$

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

As funções de transferência sinápticas nas conexões das taxas de variação dos sinais sensoriais com a inter-unidade são modeladas com características de amortecimento do tipo $x|x|$. Isso permite atenuar oscilações mantendo o sistema estável mesmo na presença de grandes taxas de variação. As equações que implementam os coeficientes a_i da eq. 7 são:

$$S_{tex} = \frac{1}{N} \left(\frac{T_r}{1 + 11(x-1)^2} \right) \quad (10)$$

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

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

Os sinais sensoriais e os sinais do nível de controle superior, juntamente com a combinação dos sinais de taxas e de erro processados por uma unidade intermediária, convergem para a unidade motora cujo sinal produzido (O) é a entrada para os atuadores. Concluindo, a unidade motora recebe três tipos de sinais: a) informação sensorial; b) comandos de nível superior; e, c) uma combinação do erro com as taxas de mudança dos sinais sensoriais. O sinal de saída é gerado conforme:

$$O = T_n \tanh \left[\alpha \left(\delta + \sum S_j + \sum S_k \right) \right], \quad (12)$$

onde S_j e S_k são as saídas sinápticas do nível de controle superior e do sistema sensorial respectivamente, e δ é o sinal gerado pela inter-unidade como função do sinal de erro e das taxas de variação.

Os sinais sensoriais e do nível superior são transmitidos por dois conjuntos simétricos, em limiar e força

de transmissão. São essas sinapses que possuem características plásticas e que serão ajustadas pelo treinamento. O modelo dessas sinapses é representado pelas equações abaixo. No início do treinamento as sinapses plásticas não transmitem nenhum sinal por não possuírem nenhuma força, i.e., para $t = 0$, $T_j = T_k = 0$. A existência de um sinal de erro ϵ , logo após o primeiro comando de *desejo*, vai gerar um sinal δ , diferente de zero, que por sua vez vai agir no sentido de aumentar, ou no sentido de diminuir a força de transmissão sináptica, inclusive para valores negativos. Esse processo mantém similaridade com os mecanismos de sensibilização, habituação e condicionamento clássico, como descrito por Kandel, Schwartz e Jessel (1998).

$$s_j = \frac{T_j}{1 + a(x_D - x_j^0)^2} \quad (13)$$

$$s_k = \frac{T_k}{1 + a(x - x_k^0)^2} \quad (14)$$

onde s_j é a saída da j -ésima sinapse conectada com "o desejo", s_k é a saída da k -ésima sinapse conectada com a condição atual, T_j e T_k são as forças dessas sinapses.

A ação da inter-unidade facilitadora sobre os contatos pré-sinápticos da unidade motora é aumentar um termo fonte. Isso é feito por meio de um processo cumulativo da forma:

$$\frac{dC}{dt} = T_c \delta - \lambda C \quad (15)$$

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

A equação 15 faz com que o gatilho da mudança de longa duração (o termo-fonte C) possa crescer proporcionalmente ao sinal de aprendizagem (δ) até um valor de equilíbrio, acelerando ou desacelerando as mudanças na força de ligação. Se o sinal de aprendizado que entra, diminuir até zero, o fator de disparo de mudança também vai a zero, de acordo com o estabelecido pela constante de decaimento (λ). Isso significa que depois de um período razoável de treinamento, quando o sinal de aprendizado tiver atingido valores insignificantes, não haverá necessidade para mudanças adicionais, fazendo com que o processo seja inerentemente estável. Para completar o mecanismo, ao processo de gatilho ainda é necessário adicionar um processo que efetue as mudanças de longa duração. Para isso é necessário que as mudanças sejam mais acentuadas nas sinapses onde o limiar (x^0) esteja mais próximo dos valores desejados da entrada, como na hipótese de ressonância de Paul Weiss (1948). Essa característica inovadora, que faz a correta seleção sináptica, é modelada considerando a

própria função matemática de transferência das sinapses. No modelo desenvolvido, a taxa de alteração do “tamanho” do contato é uma função do gatilho de mudanças, C , e da função do terminal de contato:

$$\frac{dT_j}{dt} = \frac{C}{1 + a_s(x_D - x_j^0)^2} \quad (16)$$

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

A equação 15 pode ser explicada como sendo a equação que emula o processo de acumulação de Ca^{++} dentro de um terminal sináptico, gerando um termo fonte que é o gatilho do termo de mudança de longa duração, e a equação 16 gera a taxa de mudança da força de ligação, seletivamente no terminal sináptico sintonizado com o sinal desejado (segundo a hipótese de ressonância): o processo age em cada contato sináptico da unidade alvo mas, com uma taxa de crescimento mais elevada nas sinapses que têm o limiar mais próximo do sinal desejado, ou seja, em que $x_D \Rightarrow x^0$.

3. Circuito de Circulação Natural

A Fig. 2 apresenta um esquema da Bancada de Circulação Natural (BCN), que modela um Sistema de Resfriamento de Emergência de um Reator a Água Pressurizada Avançado.

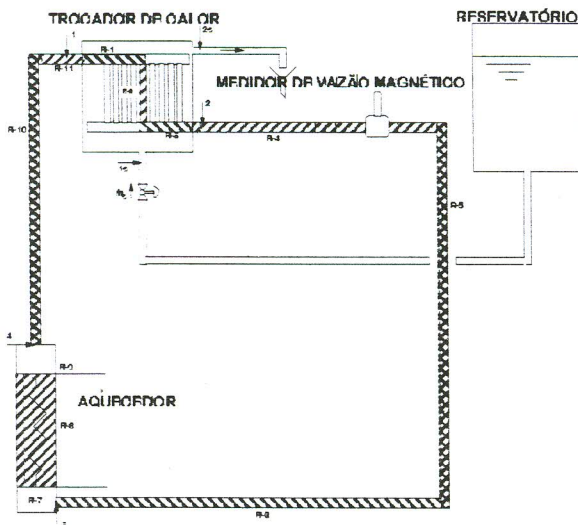


Figura 2: Esquema simplificado da BCN.

A BCN possui um aquecedor elétrico, que é a fonte quente do sistema, e um trocador de calor, que é a fonte fria. O trocador de calor é constituído por dois tubulões horizontais conectados por um feixe de tubos vertical imerso em um tanque de água. Água fria é

suprida a partir de um reservatório elevado por gravidade. Um medidor de vazão magnético está instalado na linha principal do circuito. A água de resfriamento é controlada por uma válvula globo com o auxílio de um rotâmetro.

Um modelo numérico, descrito por Baptista e Cabral (1999), foi desenvolvido para simular os processos térmicos e hidráulicos do BCN.

4. Acoplamento com a Rede MULSY

O problema da BCN consiste em controlar a temperatura da água no lado primário do circuito, em qualquer ponto especificado, atuando somente na potência do aquecedor. A temperatura e a vazão da água no lado secundário (água de resfriamento) são assumidas como perturbações, monitoradas porém fora do controle. Para a solução deste problema, a unidade básica de controle foi modificada para receber, além dos sinais de “condição desejada” e “condição atual”, no caso os sinais de *temperatura*, os sinais correspondentes às medidas de temperatura da água de resfriamento e de posição da válvula de resfriamento. Esses sinais são escalados na faixa de -1 to $+1$. A Fig. 3 mostra a rede com essas modificações. Nessa nova configuração, a unidade de controle motor da Fig. 1 é ligada a dois ramos paralelos que processam os sinais das perturbações. Cada um desses ramos possui um conjunto de “sinapses plásticas”. O modelo que representa essas conexões é o mesmo utilizado para os outros ramos, representados pela equação 2.

O sinal δ , composto pela combinação do erro com as taxas de variação da temperatura controlada é utilizado para a adaptação das forças de ligação dos novos conjuntos de “sinapses plásticas”. O sinal x_D , provê as características seletivas para essa adaptação. A saída das unidades ligadas aos sinais de perturbação são usadas para modular o ganho da unidade motora de saída (O), gerando o sinal de controle:

$$Sc = (O_1)(O_2)(O) \quad (17)$$

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

Neste problema a rede considera apenas a primeira ordem de variação do erro (1ª derivada). A grande inércia do sistema térmico elimina variações rápidas.

4.1. Dados da Rede MULSY

A Tabela 1 apresenta os dados usados na implementação da rede da Fig. 3. Esses dados são praticamente os mesmo utilizados no controle de um manipulador bi-articulado no plano conforme Baptista, Cabral, e Soares (1998). Os dados diferentes se referem ao número de terminais sinápticos e aos valores de algumas constantes. A constante de decaimento,

utilizada na adaptação das sinapses, λ , foi reduzida por uma centena de vezes (de 10 para 0.1), para se adequar à constante de tempo do processo, que é muito pequena em um processo de circulação natural. Como foi utilizado um número diferente de conexões, a constante a_s das sinapses facilitadoras foi alterada para compensar a mudança do intervalo entre limiares. Sua

relação com a constante a das sinapses plásticas continuou a mesma, i.e., $a_s/a = 144/28.8 = 100/20 = 5$. Deve ser observado ainda que, para ativar e desativar o processo de plasticidade (conforme será explicado no item referente ao treinamento), T_c assume dois valores: 0 ou 0,1.




Figura 3: Unidade de controle com dois sinais de perturbação.

Tabela 1 – Dados da Rede Neural.

Parâmetro	Valor
“Tamanho” das unidades - T_N	2.1
Constante de ganho das unidades - α	0.5
Constante das sinapses plásticas - a	20.
Qtde de terminais do ramo sensorial - kk	13
Qtde de terminais dos “desejos” - jj	13
Qtde de terminais das unidades de perturbação	13
Intervalo entre limiar de terminais consecutivos - $\Delta x = x_{j+1}^0 - x_j^0 = x_{k+1}^0 - x_k^0$	0.2
Força de ligação das sinapses de erro - T_E	2.5
Força de ligação das sinapses de taxas - T_r	0.09
Força de ligação das sinapses facilitadoras - T_c	0-0.1
Constante de decaimento das sinapses - λ	0.1
Constante das sinapses facilitadoras - a_s	100.

4.2. Treinamento

O treinamento da rede é feito durante a execução de comandos de ação. São montadas tabelas contendo os “desejos” comandados e as perturbações. São três tabelas de treinamento, cada uma para uma variável: a temperatura desejada, a perturbação na vazão de resfriamento e a perturbação na temperatura da água de resfriamento. Para resumir a apresentação apresentamos somente a primeira (Tabela 2). O treinamento é não-supervisionado, portanto os dados são as condições desejadas e perturbações, a saída necessária é descoberta pela rede. O treinamento é feito em três etapas, definidas pelas tabelas de treinamento. Os efeitos não são sobrepostos, enquanto se treina sobre uma das variáveis em mudança, a plastificação das sinapses dos neurônios de saída das outras unidades fica “congelada” fazendo $T_c = 0$. Cada uma das etapas do treinamento é realizada em sessões, observando-se a evolução gradual do aprendizado. Todo o treinamento representou um total de 615600 segundos de processo simulado, ou seja, 171 horas. Após as três etapas de treinamento, as forças de ligação dos terminais sinápticos plásticos (T_j e T_k 's da unidade motora e T_j 's das outras) cresceram do valor inicial zero para os valores utilizados nos testes. A Figura 4 ilustra os resultados de uma unidade. O treinamento sobre o tempo simulado de 171 horas foi realizado consumindo apenas 1:48h de CPU de um PENTIUM 166 MHz.

Tabela 2 – Dados de Treinamento de Temperatura

Condição	Duração (s)	T_{amb} (°C)	Temp. Resfr.	Abert. Válvula	Temp. Desej.
1	14400.	25.0	20.0	0.25	30.00
2	14400.	25.0	20.0	0.25	35.00
3	14400.	25.0	20.0	0.25	40.00
4	14400.	25.0	20.0	0.25	45.00
5	14400.	25.0	20.0	0.25	50.00
6	14400.	25.0	20.0	0.25	55.00
7	14400.	25.0	20.0	0.25	25.00

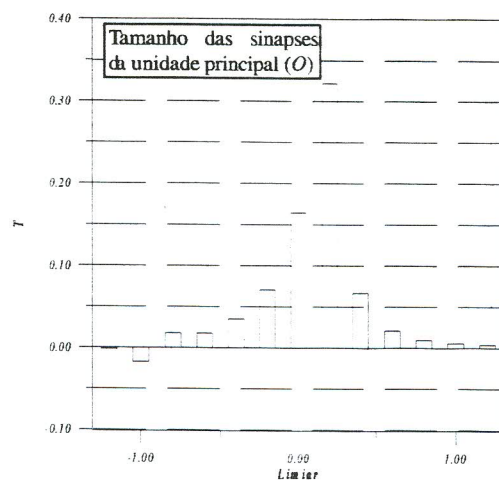


Figura 4: Forças Sinápticas após o 1º estágio.

4.3. Testes de desempenho

Após o treinamento acima, a rede foi capaz de atender comandos de temperatura desejada sob diversas condições de perturbação de abertura da válvula e de variação na temperatura de resfriamento. Os testes apresentados verificam a capacidade de generalização pela execução de comandos não presentes no treinamento. Nesta fase foram bloqueados os mecanismos de plasticidade anulando-se a força de ligação de todas as sinapses facilitadoras, $T_c = 0$. A partir daí foram executados testes sobre todo o domínio possível, limitados pelas condições impostas pelo processo em si.

Fig. 6 apresenta resultados de um teste com vários transitórios durante 26 horas. O teste se inicia com temperatura ambiente de 25°C e temperatura de resfriamento de 20°C. O primeiro comando solicita uma temperatura de 50°C na saída do aquecedor, com a vazão de resfriamento determinada pela abertura da válvula em 25%. Alguns valores do teste estão fora das faixas consideradas no treinamento, outros dentro dessas faixas porém não coincidentes com nenhum. A duração da primeira condição permite à BCN aproximar o regime permanente. Para isso o processo requer 22.000 segundos, determinados experimentalmente. O tempo de 16.000 segundos é suficiente apenas para a aproximação do regime permanente no lado primário do trocador de calor. Todos os outros estágios duraram 7.200 segundos, o que representa aproximadamente 1/3 do tempo necessário para estabilização e leva a uma aproximação em torno de 95% da temperatura de regime. Essa condição adiciona algum erro à aproximação mas já é suficiente para avaliação da rede.




Figura 6: Evolução do erro de temperatura

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

ção de *Abertura da válvula 0,08* com a demanda de uma temperatura desejada 5°C acima da maior temperatura considerada no treinamento, ou seja $T_{des}=60^\circ\text{C}$.

5. Conclusões

Demonstrado anteriormente por Baptista, Cabral, e Soares (1998), a opção de arquiteturas especializadas por tarefa e o uso de contatos sinápticos múltiplos aumenta a capacidade de integração da rede. Funções de transferência sinápticas mais complexas que pesos de ligação melhoram a relação entrada/saída e permitem a redução no número de unidades. O treinamento ocorre durante a execução de comandos, dispensando a necessidade de exemplos x/y, ou seja, é um treinamento não-supervisionado. Neste trabalho a rede MULSY foi aperfeiçoada para acomodar perturbações externas. Os resultados obtidos no controle de temperatura do BCN, mesmo na presença de perturbações além das faixas utilizadas durante o treinamento, mostraram que a rede apresenta capacidade de generalização e robustez.

Agradecimentos

Os autores agradecem o suporte financeiro dado pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) para a apresentação deste trabalho.

Referências

- [1] 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.
- [2] Baptista F., B. D., *Redes Neurais Artificiais para Controle de Sistemas de Reatores Nucleares*, São Paulo: 1998, Thesis (Doctoral) – Instituto de Pesquisas Energéticas e Nucleares.
- [3] B.D. Baptista F., E.L.L. Cabral, "Planar Two-Link Manipulator Control with Multiple-Synapse Neural Network Controller", *IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM'99)*, pp. 647-652, Sept. 19-23, 1999, Atlanta, USA.
- [4] Baptista F., B.D., "Utilização do Conceito de Redes Neurais com Contatos Sinápticos Múltiplos no Controle de Trajetória de um Manipulador Bi-Articulado", REF. AC9828, Congresso Nacional de Engenharia Mecânica, CONEM2000, Agosto de 2000.
- [5] Macedo, L.A., Baptista F., B.D., "Caracterização da Bancada de Circulação Natural de Sistemas de Resfriamento de Emergência em Reatores Navais e Reatores Avançados", Ref. DC9778, Congresso Nacional de Engenharia Mecânica, CONEM2000, Agosto de 2000.
- [6] Kolen, J.F., Goel, A.K., 1991, "Learning in Parallel Distributed Processing Networks: Computational Complexity and Information Content", *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 21, No. 2.
- [7] Kandel, E.R., Schwartz, J.H., Jessel, T.M., 1991, *Principles of Neural Science*, Prentice-Hall International Inc., Third Edition.
- [8] Weiss, P., Hiscoe, H.B., 1948, "Experiments on the mechanism of nerve growth", *J. Exp. Zool.*, 107:315-395.