

## INSTRUÇÕES DE USO:

--:: MS Windows ::--

- 1) Insira o CD no drive
- 2) Caso o programa não inicie automaticamente dê um duplo-clique no arquivo cba2002\_win.exe localizado na raiz do CD. Exemplo: D:\cba2002\_win.exe

--:: Linux ::--

- 1) Insira e monte o CD. Exemplo: mount /mnt/cdrom
- 2) Entre no diretório montado. Exemplo: cd /mnt/cdrom
- 3) Execute o programa assim: ./cba2002\_lin.sh

--:: Outros Sistemas ::--

- 1) Abra em qualquer navegador Web o arquivo index.html que se encontra na raiz do CD.



IDENTIFICAÇÃO E CONTROLE DE SISTEMAS DINÂMICOS  
USANDO A REDE AUTO-ORGANIZÁVEL DE KOHONEN

GUILHERME DE A. BARRETO, ALUIZIO F. R. ARAÚJO

*Laboratório de Sistemas Inteligentes, Depto. de Engenharia Elétrica**Universidade de São Paulo, 13560-590, São Carlos, SP, Brasil**E-mails: gbarreto@sel.eesc.sc.usp.br, aluizioa@sel.eesc.sc.usp.br*

**Resumo**— Uma nova técnica não-supervisionada de modelagem neural, chamada *Memória Associativa Temporal via Quantização Vetorial* (MATQV) é proposta neste artigo. MATQV é utilizada na identificação de sistemas dinâmicos não-lineares a partir das séries temporais das variáveis de entrada e saída. Usando esta abordagem, mostra-se que a rede auto-organizável de Kohonen (SOM, em inglês) produz resultados similares aos gerados por redes MLP e melhores do que os gerados por redes RBF, ambas de treinamento supervisionado. Além disso, a rede de Kohonen é mais robusta a variações nos valores iniciais dos pesos que as redes MLP e RBF. As três redes são avaliadas por simulação computacional em tarefas de modelagem direta, modelagem inversa de um atuador hidráulico e aprendizagem de trajetórias robóticas complexas. Todas elas são também comparadas com métodos usuais de identificação linear. Sugestões para pesquisa futura são fornecidas no final do artigo.

**Abstract**— In this paper we propose an unsupervised neural modelling technique, called *Vector-Quantized Temporal Associative Memory* (VQTAM), to identifying dynamical nonlinear systems from time series of measured input-output data. Using the VQTAM approach, the Kohonen's self-organizing map (SOM) is shown to produce modelling results equivalent to those obtained by MLP networks, and better than those produced by the RBF networks, both the MLP and the RBF based on supervised training. In addition, the SOM is less sensitive to weight initialization than the MLP and RBF networks. The three networks are evaluated through simulations involving learning of feedforward and inverse models of a hydraulic actuator and learning of complex robot trajectories. All the neural networks are also compared with the usual linear identification method. Directions for further research are provided at the end of the paper.

**Key Words**— System identification; nonlinear systems; neural networks; self-organization; time series analysis; robotics.


## 1 Introdução

Identificação de sistemas é o campo de pesquisa interessado na construção de modelos matemáticos de sistemas dinâmicos a partir das séries temporais das variáveis de entrada e saída medidas (Aguirre, 2000). Estes modelos podem ser lineares ou não-lineares, dependendo do tipo de processo ou planta que se quer identificar. Mais recentemente, técnicas de identificação e controle de sistemas não-lineares têm recebido especial atenção em engenharia de controle porque muitos sistemas, tais como plantas químicas e manipuladores robóticos, exibem elevado grau de não-linearidade. Para tais sistemas, a utilização de modelos lineares se mostra ineficaz porque, em geral, propriedades importantes da dinâmica do sistema não são capturadas.

Modelos de redes neurais artificiais (RNAs) têm sido aplicados com sucesso na identificação e controle de sistemas não-lineares (Nascimento e Yoneyama, 2000). Isto se deve em parte ao fato de certas arquiteturas de redes neurais, tais como redes do tipo perceptron multicamadas (MLP) e de função de base radial (RBF), ambas de treinamento supervisionado, podem representar com precisão arbitrária qualquer mapeamento não-linear entre a entrada e a saída de um sistema (Hunt et al., 1992). Tais redes podem ser treinadas para descrever a dinâmica não-linear

do processo em uma ampla faixa de operação, provendo assim uma representação fiel do mesmo sobre a qual pode-se projetar e desenvolver vários esquemas de controle (Norgaard et al., 2000). Por se tratar de uma técnica de identificação do tipo caixa-preta (*black-box*), o conhecimento a respeito das características dinâmicas do mapeamento é representado implicitamente nos padrões de conectividade e ativação dos neurônios da rede. A performance desses esquemas de controle dependerá da precisão da aproximação fornecida pelo modelo neural. O uso de RNAs em identificação e controle é justificado também por outras propriedades, tais como a robustez a ruído e capacidade de generalização.

Neste artigo propõe-se uma nova técnica neural de modelagem (ou identificação) caixa-preta que utiliza redes de treinamento não-supervisionado, ao contrário da abordagem convencional que utiliza apenas redes de treinamento supervisionado (MLP e RBF). Por meio desta técnica, chamada de *Memória Associativa Temporal via Quantização Vetorial* (MATQV), mostra-se que a rede auto-organizável proposta por Kohonen (1997) (SOM, em inglês) pode ser utilizada para aproximar mapeamentos entrada-saída dinâmicos e não-lineares. Simulações demonstram a capacidade de aproximação da rede SOM usando a técnica MATQV e comparam os resultados obtidos com aqueles das redes MLP e





RBF e de técnicas lineares.

O restante do artigo está organizado como segue. A Seção 2 traz um breve resumo da rede de Kohonen e de como tal arquitetura pode ser estendida para processar séries temporais. A Seção 3 introduz a técnica MATQV e suas principais características, mostrando como ela pode ser usada em conjunto com a rede SOM na identificação das dinâmicas direta e inversa de um atuador hidráulico e na aprendizagem e reprodução de trajetórias robóticas complexas. A Seção 4 mostra os resultados da comparação da MATQV com as redes MLP e RBF e com uma técnica linear. A Seção 5 conclui o artigo.

## 2 Introduzindo Dinâmica na Rede SOM

A rede auto-organizável de Kohonen é um algoritmo neural de treinamento não-supervisionado desenvolvido para representar relações de proximidade espacial entre os vetores-amostras de um conjunto (Kohonen, 1997). Os neurônios desta rede estão dispostos em uma camada de saída,  $\mathcal{A}$ , em arranjos (*arrays*) de uma, duas e até três dimensões. Cada neurônio  $i \in \mathcal{A}$  possui um vetor de pesos  $\mathbf{w}_i \in \mathbb{R}^n$  com a mesma dimensão do vetor de entrada  $\mathbf{x} \in \mathbb{R}^n$ . O algoritmo de aprendizagem pode ser resumido em dois passos principais:

1. Busca pelo neurônio vencedor,  $i^*$ :

$$i^*(t) = \arg \min_{i \in \mathcal{A}} \|\mathbf{x}(t) - \mathbf{w}_i(t)\| \quad (1)$$

2. Ajuste dos pesos,  $\mathbf{w}_i$ , da rede:

$$\Delta \mathbf{w}_i(t) = \eta(t) h(i^*, i; t) [\mathbf{x}(t) - \mathbf{w}_i(t)] \quad (2)$$

onde  $\eta(t)$  é a taxa de aprendizagem e  $h(i^*, i; t)$  é a função vizinhança do tipo gaussiana:

$$h(i^*, i; t) = \exp \left( -\frac{\|\mathbf{r}_i(t) - \mathbf{r}_{i^*}(t)\|^2}{\sigma^2(t)} \right) \quad (3)$$

onde  $\mathbf{r}_i(t)$  e  $\mathbf{r}_{i^*}(t)$  são, respectivamente, as posições dos neurônios  $i$  e  $i^*$  no arranjo. As variáveis  $0 < \eta(t), \sigma(t) < 1$  decaem exponencialmente com o passar do tempo:  $\eta(t) = \eta_0(\eta_T/\eta_0)^{(t/T)}$  e  $\sigma(t) = \sigma_0(\sigma_T/\sigma_0)^{(t/T)}$ , onde  $\eta_0$  e  $\sigma_0$  são os valores iniciais e  $\eta_T$  e  $\sigma_T$  os finais de  $\eta(t)$  e  $\sigma(t)$ , transcorridas  $T$  iterações de treinamento.

Uma importante característica da rede SOM original é que ela aprende apenas mapeamentos entrada-saída *estáticos* (Walter e Ritter, 1996). Tais mapeamentos são usualmente descritos matematicamente por  $\mathbf{y}(t) = \mathbf{f}(\mathbf{u}(t))$ , onde  $\mathbf{u}(t) \in \mathbb{R}^n$  e  $\mathbf{y}(t) \in \mathbb{R}^m$  denotam, respectivamente, o vetor de entrada e o vetor de saída do sistema. O interesse deste artigo é mostrar que, com pequenas modificações, a rede SOM pode também ser utilizada para aproximar mapeamentos dinâmicos.

Assume-se que tais mapeamentos podem ser descritos pela seguinte equação (Hunt et al., 1992):

$$\mathbf{y}(t+1) = \mathbf{f}[\mathbf{y}(t), \dots, \mathbf{y}(t-n_y+1); \mathbf{u}(t), \dots, \mathbf{u}(t-n_u+1)] \quad (4)$$

onde  $n_u$  e  $n_y$  são os tamanhos máximos (ordens) da memória de entrada e de saída, respectivamente. De acordo com (4), a saída do sistema no instante  $t+1$ , depende dos  $n_y$  valores passados da saída e dos  $n_u$  valores passados da entrada. Esta dependência, definida pela função  $\mathbf{f}(\cdot)$ , é em geral não-linear e desconhecida.

Em muitos problemas de identificação deseja-se também identificar a dinâmica inversa da planta:

$$\mathbf{u}(t) = \mathbf{f}^{-1}[\mathbf{r}(t+1), \mathbf{y}(t), \dots, \mathbf{y}(t-n_y+1); \mathbf{u}(t-1), \dots, \mathbf{u}(t-n_u+1)] \quad (5)$$

onde, para fins de controle, o sinal  $\mathbf{y}(t+1)$  é substituído pelo sinal de referência  $\mathbf{r}(t+1)$ . Para a rede SOM ser capaz de aprender mapeamentos dinâmicos, ela deve possuir algum tipo de mecanismo de *memória de curta duração* (MCD) (Barreto e Araújo, 2001), ou seja, ela deve ser capaz de armazenar informação passada sobre os vetores de entrada e saída do sistema de interesse. MCD permite que a rede SOM seja capaz de processar dados de natureza temporal, também chamados *sequências* ou *séries temporais*.

Atualmente quatro técnicas vêm sendo utilizadas com este propósito. A primeira e mais comum delas adiciona informação temporal à entrada da rede SOM por meio de atrasadores (*delay lines*) ou integradores (*leaky integrators*). A segunda técnica adiciona informação temporal internamente à rede SOM, nas regras de ativação e/ou aprendizagem. A terceira técnica combina a primeira e segunda técnicas em diversas redes SOM dispostas em camadas, tentando aprender relações temporais por meio de sucessivos refinamentos da informação de entrada. A quarta técnica usa laços de realimentação para inserir informação temporal na rede SOM. Na próxima seção mostra-se como a rede SOM, graças a mecanismos de MCD, pode aprender mapeamentos entrada-saída dinâmicos. Para simplificar a exposição, serão usados apenas atrasadores para armazenar informação temporal.

## 3 Memória Associativa Temporal

Deseja-se utilizar a rede SOM para obter uma aproximação da função  $\mathbf{f}$  ou de sua inversa  $\mathbf{f}^{-1}$  de posse apenas das séries temporais das variáveis de entrada e saída,  $\{\mathbf{u}(t), \mathbf{y}(t)\}$ ,  $t = 1, \dots, N$ . Para tanto, modifica-se o vetor de entrada da rede SOM para que ele passe a ter duas partes. A primeira parte, representada por  $\mathbf{x}^{in}(t)$ , corresponde à informação de entrada do mapeamento que se quer



aproximar. A segunda, representada por  $\mathbf{x}^{out}(t)$ , corresponde à informação de saída desse mesmo mapeamento. Como consequência, os vetores de pesos dos neurônios  $i$  têm também suas dimensões aumentadas. Matematicamente, tem-se que:

$$\mathbf{x}(t) = \begin{pmatrix} \mathbf{x}^{in}(t) \\ \mathbf{x}^{out}(t) \end{pmatrix} \quad \text{e} \quad \mathbf{w}_i(t) = \begin{pmatrix} \mathbf{w}_i^{in}(t) \\ \mathbf{w}_i^{out}(t) \end{pmatrix} \quad (6)$$

É importante notar a diferença desta estratégia em relação àquela usada no treinamento de redes supervisionadas (MLP ou RBF). Nestas redes o vetor  $\mathbf{x}^{in}(t)$  é utilizado na entrada da rede, enquanto o vetor  $\mathbf{x}^{out}(t)$  é utilizado na saída. Quando se usa a rede SOM com as definições dadas em (6) o vetor  $\mathbf{x}^{out}(t)$  é apresentado na entrada da rede juntamente com o vetor  $\mathbf{x}^{in}(t)$ .

Dependendo da escolha das variáveis que compõem os vetores  $\mathbf{x}^{in}(t)$  e  $\mathbf{x}^{out}(t)$  pode-se utilizar a rede SOM para aprender tanto a dinâmica direta quanto a inversa de uma planta não-linear. Por exemplo, para o caso de se querer aproximar a dinâmica direta, representada em (4), define-se:

$$\mathbf{x}^{in}(t) = [\mathbf{y}(t), \dots, \mathbf{y}(t - n_y + 1); \mathbf{u}(t), \dots, \mathbf{u}(t - n_u + 1)] \quad (7)$$

$$\mathbf{x}^{out}(t) = \mathbf{y}(t + 1) \quad (8)$$

Já para o caso da dinâmica inversa tem-se as seguintes definições:

$$\mathbf{x}^{in}(t) = [\mathbf{y}(t + 1), \mathbf{y}(t), \dots, \mathbf{y}(t - n_y + 1); \mathbf{u}(t - 1), \dots, \mathbf{u}(t - n_u + 1)] \quad (9)$$

$$\mathbf{x}^{out}(t) = \mathbf{u}(t) \quad (10)$$

Durante o treinamento, os neurônios vencedores são encontrados usando apenas a porção correspondente a  $\mathbf{x}^{in}(t)$ :

$$i^*(t) = \arg \min_{i \in A} \{\|\mathbf{x}^{in}(t) - \mathbf{w}_i^{in}(t)\|\} \quad (11)$$

Na atualização dos pesos, ambos  $\mathbf{x}^{in}(t)$  e  $\mathbf{x}^{out}(t)$  são utilizados:

$$\Delta \mathbf{w}_i^{in}(t) = \eta(t) h(i^*, i; t) [\mathbf{x}^{in}(t) - \mathbf{w}_i^{in}(t)] \quad (12)$$

$$\Delta \mathbf{w}_i^{out}(t) = \eta(t) h(i^*, i; t) [\mathbf{x}^{out}(t) - \mathbf{w}_i^{out}(t)] \quad (13)$$

Com o transcorrer do treinamento, a rede SOM aprende a associar os sinais de saída do mapeamento com os sinais de entrada correspondentes, ao mesmo tempo que realiza a quantização vetorial dos espaços de entrada e saída. Por isso, esta técnica será chamada de *Memória Associativa Temporal via Quantização Vetorial* (MATQV). Após o treinamento, a rede SOM é utilizada para obter estimativas dos valores de saída dos mapeamentos, a partir do vetor de pesos  $\mathbf{w}_{i^*}^{out}(t)$  do neurônio vencedor. Assim, para o caso da aproximação da dinâmica direta, tem-se que:

$$\hat{\mathbf{y}}(t + 1) \equiv \mathbf{w}_{i^*}^{out}(t) \quad (14)$$

E para o caso de aproximação da dinâmica inversa, tem-se:

$$\hat{\mathbf{u}}(t) = \mathbf{w}_{i^*}^{out}(t) \quad (15)$$

onde em ambos os casos o neurônio vencedor  $i^*(t)$  é determinado segundo (11). O processo de estimação é repetido por  $M$  passos até se obter uma nova série temporal totalmente formada por valores estimados.

### 3.1 Aprendizagem de Trajetórias Robóticas

Usando a técnica MATQV é possível utilizar a rede SOM na aprendizagem e reprodução de trajetórias robóticas complexas (Araújo e Barreto, 2002). O objetivo é fazer com que a rede aprenda a estimar a próxima posição angular do braço do robô PUMA 560 durante a execução de uma trajetória contendo estados repetidos. Assumindo aqui, como variáveis de entrada, as posições cartesianas do efetuator do robô,  $\mathbf{x}(t) = (x_1(t), x_2(t), x_3(t))$ , e como variáveis de saída os ângulos das juntas,  $\boldsymbol{\theta}(t) = (\theta_1(t), \dots, \theta_6(t))$ , então pode-se escrever uma versão de (4), adaptada ao problema de aprendizagem de trajetórias robóticas:

$$\boldsymbol{\theta}(t + 1) = f[\boldsymbol{\theta}(t), \dots, \boldsymbol{\theta}(t - n_\theta + 1); \mathbf{x}(t), \dots, \mathbf{x}(t - n_x + 1)] \quad (16)$$

Para este caso, os vetores  $\mathbf{x}^{in}(t)$  e  $\mathbf{x}^{out}(t)$  são os seguintes:

$$\mathbf{x}^{in}(t) = [\boldsymbol{\theta}(t), \dots, \boldsymbol{\theta}(t - n_\theta + 1); \mathbf{x}(t), \dots, \mathbf{x}(t - n_x + 1)] \quad (17)$$

$$\mathbf{x}^{out}(t) = \boldsymbol{\theta}(t + 1) \quad (18)$$

onde a determinação do neurônio vencedor obedece (11) e o ajuste dos pesos segue (12) e (13). A estimativa gerada,  $\hat{\boldsymbol{\theta}}(t + 1) \equiv \mathbf{w}_{i^*}^{out}(t)$ , é usada para fins de controle do manipulador. Na próxima seção são mostradas simulações com a rede SOM na identificação inversa e direta de um atuador hidráulico e na aprendizagem de trajetórias robóticas.

## 4 Simulações Computacionais

As redes SOM, MLP e RBF são aplicadas na identificação de um atuador hidráulico, utilizado por Sjöberg et al. (1995). Para esta planta, pressão do óleo é controlada pela abertura da válvula através da qual o óleo flui para dentro do atuador. Assim, a posição do atuador é uma função da pressão do óleo. Na Figura 1 estão mostrados os valores medidos da abertura da válvula,  $u \in \mathbb{R}$ , e da pressão do óleo,  $y \in \mathbb{R}$ , que fazem o papel de sinais de entrada e saída respectivamente. Nota-se um comportamento oscilante da variável de saída, causado por ressonâncias mecânicas presentes no atuador. Na tarefa de identificação da dinâmica




Figura 1. Valores medidos da pressão do óleo (superior) e da posição da válvula (inferior).

direta do atuador hidráulico, as três redes neurais são também comparadas com o modelo linear usual conhecido como *Modelo Autoregressivo com Entradas Exógenas* (ARX, em inglês):  $\hat{y}(t+1) = \sum_{i=0}^{n_y-1} a_i \hat{y}(t-i) + \sum_{j=1}^{n_u-1} b_j u(t-j)$ , onde  $a_i$  e  $b_j$  são os coeficientes do modelo ARX e  $\hat{y}(t+1)$  é o valor estimado para a saída para o instante  $t+1$ . Os coeficientes são calculados pelo método dos mínimos quadrados (Aguirre, 2000). A precisão da aproximação medida pelo raiz do erro médio quadrático (RMSE, em inglês):

$$RMSE = \sqrt{\frac{1}{M} \sum_{t=0}^{M-1} (o(t) - \mathbf{w}_{i^*}^{out}(t))^2} \quad (19)$$

onde  $o(t) = y(t+1)$  (se identificação direta) ou  $o(t) = u(t)$  (se identificação inversa), e  $M$  é o tamanho da série estimada. Os dados são processados pelos quatro modelos sem nenhum tipo de normalização prévia, ou seja, na mesma escala em que foram medidos. De um total de  $N = 1024$  amostras para cada uma das séries de entrada e saída, as 512 primeiras são utilizadas para ajuste dos pesos das redes neurais e para cálculo dos coeficientes do modelo ARX. As 512 últimas amostras são usadas para validação dos quatro modelos. Para todas as simulações adotou-se  $n_y = 3$  e  $n_u = 2$ . Outros valores para  $n_u$  e  $n_y$  resultam em erros de aproximação levemente maiores que os apresentados a seguir. O resultado obtido pelo modelo ARX está mostrado na Figura 2, onde se nota que os valores preditos não foram muito precisos ( $RMSE = 1,0133$ ).

A rede MLP possui 5 unidades de entrada, uma camada escondida com dez neurônios e um neurônio de saída. Os neurônios da camada escondida têm função de transferência do tipo tangente hiperbólica e a do neurônio de saída é linear. O algoritmo de treinamento foi o de retropropagação do erro com fator de momento. Os valores da taxa de




Figura 2. Modelo ARX: Sinal simulado (linha sólida) e valor real da pressão do óleo (linha tracejada).

aprendizagem e do fator de momento foram, respectivamente, iguais a 0,2 e 0,9. O treinamento é finalizado se  $RMSE \leq 10^{-4}$  ou se o número máximo de 600 épocas de treinamento é atingido. Cada época corresponde a apresentação de um total de  $512 - n_y = 509$  amostras extraídas da primeira parte da série.

A rede RBF possui 5 unidades de entrada, uma camada intermediária com neurônios de função de base do tipo gaussiana e um neurônio de saída. Seguindo o esquema proposto por Specht (1991), específico para problemas de regressão não-linear, o número de neurônios da camada intermediária é igual ao número de vetores de treinamento, sendo que os centros destes neurônios são as próprias vetores de treinamento. Assim, um total de 509 neurônios foram usados na camada intermediária. Não há treinamento para este tipo de rede RBF, já que as amostras de treinamento são copiadas diretamente para os centros. Aos pesos da camada intermediária para a de saída são simplesmente atribuídos os valores desejados para a saída. O único parâmetro ajustável nesta rede é o que regula a abertura da função de base gaussiana. Este parâmetro foi variado de 0,1 a 1,0 para se avaliar seu efeito na precisão da aproximação.

Uma rede SOM com 500 neurônios (dispostos em uma dimensão) é utilizada nas tarefas de identificação das dinâmicas direta e inversa do atuador hidráulico. Os pesos sinápticos destes neurônios recebem valores aleatórios entre 0 e 1 no início do treinamento. O ajuste dos pesos é executado por 600 épocas e os parâmetros de treinamento são:  $\eta_0 = 0,9$ ,  $\eta_T = 10^{-5}$ ,  $\sigma_0 = 250$  e  $\sigma_T = 10^{-3}$ . Os resultados obtidos para as três redes na identificação das dinâmicas direta e inversa do atuador hidráulico, usando os dados de validação, estão mostrados na Tabela 1. Para as redes SOM e MLP foram executadas 10 rodadas de treinamento, cada uma com diferentes valores iniciais para os pesos. Como não há treinamento para a rede RBF, o parâmetro que regula a abertura da




Figura 3. Resultado obtido pela rede SOM na identificação da dinâmica direta usando MATQV.

função de base gaussiana foi variado de 0,1 a 1,0 em incrementos de 0,1.

Tabela 1. Comparação entre as redes SOM, MLP e RBF na identificação da dinâmica direta e inversa.

Identificação Direta				
RMSE	Min	Max	Média	$\sqrt{var}$
MLP	0,1162	0,2493	0,1554	0,0457
SOM	0,2051	0,2665	0,2259	0,0215
RBF	0,2067	0,4103	0,2994	0,0774
Identificação Inversa				
RMSE	Min	Max	Média	$\sqrt{var}$
MLP	0,0566	0,4789	0,1446	0,1259
SOM	0,1189	0,1255	0,1207	0,0021
RBF	0,1398	0,2841	0,2032	0,0551

Nota-se que a rede MLP produz em geral os melhores resultados. A rede SOM, por sua vez, produz melhores resultados que uma rede RBF com aproximadamente o mesmo número de neurônios. A Figura 3 mostra o melhor resultado obtido pela rede SOM na identificação direta. Um resultado interessante está no fato de a rede SOM ser menos sensível a variações dos valores iniciais dos pesos que a rede MLP, conforme pode ser visto na quinta coluna da Tabela 1. Esta sensibilidade é medida pelo desvio-padrão dos erros obtidos para as 10 rodadas de treinamento. Apesar de treinadas para um número fixo de épocas, observou-se também que a rede SOM converge muitas vezes mais rapidamente que a rede MLP.

Outra dificuldade encontrada com a rede MLP está na ocorrência de *overfitting* durante o treinamento (fortemente relacionado com a escolha do número de neurônios da camada escondida), resultando algumas vezes numa baixa performance (*RMSE* alto) durante a validação do modelo. A rede SOM não padece desse problema por se tratar de um algoritmo de quantização vetorial, ou seja, quanto mais neurônios melhor será a aproximação. O efeito da variação de alguns

parâmetros da rede SOM, tais como o número de neurônios e o número de épocas usadas para treinamento (ambos variados de 1 a 500), na qualidade do resultado da identificação está mostrado na Figura 4. Note que em ambos os casos o erro tende a um valor em torno de  $RMSE = 0,20$ .




Figura 4. Efeito da variação do número de neurônios (círculos) e do número de épocas de treinamento (triângulos) da rede SOM na identificação direta.

O resultado obtido pelas redes SOM, RBF e MLP na aproximação da dinâmica inversa estão mostrados na Figura 5. Para este caso específico os erros de estimação foram  $RMSE(SOM) = 0,1189$ ,  $RMSE(RBF) = 0,1398$  e  $RMSE(MLP) = 0,0566$ . Note que a aproximação da dinâmica inversa pelas redes SOM e RBF apresentam erros elevado em alguns trechos que a da dinâmica direta. A própria rede MLP, que produz o melhor resultado entre as três estudadas, apresenta alguns trechos em que o erro de estimação também é alto. Isto se deve ao fato que alguns sistemas não possuem um único mapeamento inverso, mas sim vários, dificultando o processo de aproximação.

Para avaliar a rede SOM no problema de aprendizagem e reprodução de trajetórias robóticas treinou-se uma rede com 75 neurônios, cujos pesos receberam valores iniciais aleatórios entre 0 e 1. Esta rede foi treinada durante 600 épocas de treinamento usando uma seqüência de 97 estados que fazem o efetuador do robô descrever uma trajetória em forma de oito no espaço euclidiano. Ao término do treinamento, testou-se a capacidade de generalização da rede SOM apresentando uma outra seqüência de 49 pontos que descreve a mesma trajetória em forma de oito. A Figura 6 mostra a trajetória angular estimada pela rede SOM para a terceira junta (cotovelo) do robô PUMA. Para este caso, o erro de estimação foi  $RMSE = 1,5453$ . É interessante comparar a rede SOM com a rede neural auto-organizável proposta por Araújo e Barreto (2002), chamada de rede Competitiva e Hebbiana Temporal (CHT), especificamente projetada para aprender e reproduzir trajetórias robóticas. A rede CHT exige 97 neurônios para aprender a mesma trajetória usada para treinar a rede SOM, enquanto a rede SOM




Figura 5. Resultado obtido pelas redes SOM (gráfico superior), RBF (gráfico intermediário) e MLP (gráfico inferior) na identificação da dinâmica inversa do atuador hidráulico.

treinada via MATQV usa apenas 75 neurônios. Além disso, a rede CHT só é capaz de reproduzir a trajetória que foi armazenada, não sendo capaz de generalizar (interpolar) como a rede SOM.

## 5 Conclusão

As simulações mostradas neste artigo são preliminares, mas ilustram o potencial da técnica MATQV. Testes adicionais necessitam ser executados, tais como análise dos resíduos do erro de estimação, tolerância ao ruído, para demonstrar efetivamente a viabilidade de se utilizar a rede SOM em tarefas de identificação e controle de sistemas dinâmicos não-lineares. A pesquisa em andamento envolve o projeto de um controlador preditivo não-linear usando MATQV e na demonstração teórica de que a rede SOM, usando

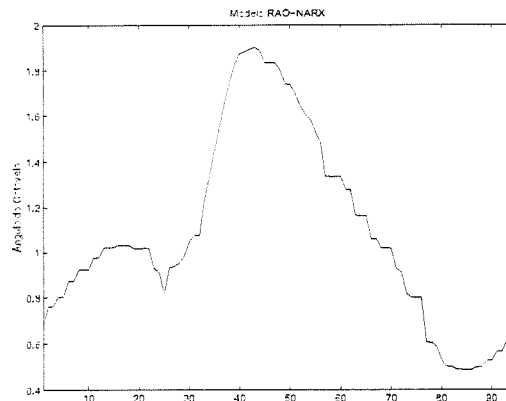


Figura 6. Valor produzido pela rede SOM (linha sólida) e valor real (linha tracejada) da trajetória do ângulo da 3a. junta do robô PUMA 560 para trajetória em oito.

MATQV, pode ser usada como aproximador universal de funções entrada-saída.

## Agradecimentos

Agradecemos à FAPESP por financiar esta pesquisa (projeto de doutorado 98/12699-7).

## Referências Bibliográficas

- Aguirre, L. A. (2000). *Introdução à Identificação de Sistemas*, Editora UFMG, Belo Horizonte.
- Araújo, A. F. R. e Barreto, G. A. (2002). Context in temporal sequence processing: A self-organizing approach and its application to robotics, *IEEE Trans. on Neural Networks* **13**(1): 45-57.
- Barreto, G. A. e Araújo, A. F. R. (2001). Time in self-organizing maps: An overview of models, *Int. J. Computer Research* **10**(2): 139-179.
- Hunt, K. J., Sbarbaro, D., Zbikowski, R. e Gawthrop, P. J. (1992). Neural networks for control systems - A survey, *Automatica* **28**(6): 1083-1112.
- Kohonen, T. (1997). *Self-Organizing Maps*, 2nd extended edn, Springer-Verlag, Berlin, Heidelberg.
- Nascimento, C. L. e Yoneyama, T. (2000). *Inteligência Artificial em Controle e Automação*, Editora Edgard Blücher, São Paulo, SP.
- Norgaard, M., Ravn, O., Poulsen, N. K. e Hansen, L. K. (2000). *Neural Networks for Modelling and Control of Dynamic Systems*, Springer-Verlag.
- Sjöberg, J., Zhang, Q., Ljung, L., Benveniste, A., Deylon, B., Glorennec, P.-Y., Hjalmarsson, H. e Juditsky, A. (1995). Nonlinear black-box modeling in system identification: A unified overview, *Automatica* **31**(12): 1691-1724.
- Specht, D. F. (1991). A generalized regression neural network, *IEEE Trans. on Neural Networks* **2**(5): 568-576.
- Walter, J. e Ritter, H. (1996). Rapid learning with parametrized self-organizing maps, *Neurocomputing* **12**: 131-153.