

## 1º Congresso Brasileiro de Redes Neurais

Escola Federal de Engenharia de Itajubá  
Itajubá, 24 a 27 de outubro de 1994

# IMPLEMENTAÇÃO EM LABORATÓRIO DE UM ESTIMADOR DE SISTEMAS DINÂMICOS NÃO-LINEARES USANDO REDES NEURAIS ARTIFICIAIS

Sérgio R. J. Oliveira e Edilberto P. Teixeira  
Universidade Federal de Uberlândia  
Departamento de Engenharia Elétrica  
38400 Uberlândia - MG  
Tel: (034) 235 2888 R 166  
Fax: (034) 236 5099

### RESUMO

Este artigo apresenta um método para estimação da dinâmica direta de uma classe de sistemas dinâmicos não-lineares. O método considera que as equações do sistema sejam desconhecidas. Para isso, aplica-se uma rede neural de várias camadas, capaz de estimar um mapeamento que aproxima a dinâmica direta do sistema, dentro de uma determinada faixa de operação. O método foi aplicado na estimação da dinâmica direta do conjunto composto por um motor C.C., acoplado a um gerador de indução e acionado por um retificador controlado de 6 pulsos. Os resultados apresentados foram obtidos da montagem realizada no laboratório de Automação e Robótica do Departamento de Engenharia Elétrica da Universidade Federal de Uberlândia.

### 1 - INTRODUÇÃO

As redes neurais artificiais (RNA) têm sido aplicadas nas mais diversas áreas, desde o desenvolvimento dos princípios básicos da computação neural por Mc Cullow e Pitts, e do estabelecimento da regra de Hebb [1]. A criação do algoritmo de propagação retroativa [1], para o treinamento de redes neurais de múltiplas camadas (RNMC), tem contribuído para o grande uso desse tipo de rede. As redes neurais de várias camadas se aplicam muito bem para a estimação de mapeamentos não-lineares. Neste sentido, este trabalho trata de uma aplicação das redes neurais de várias camadas, na estimação da dinâmica direta um sistema não-linear implementado em laboratório. Inicialmente, apresentam-se as classes de sistemas não-lineares

às quais se aplica o método em questão. Em seguida, é feita uma descrição do método proposto, para estimação do sistema não-linear. Finalmente, são apresentados os resultados da aplicação do método para a estimação da dinâmica direta de um sistema não-linear composto por um motor C.C. acoplado a um gerador de indução e excitado por um retificador controlado de 6 pulsos, montado em laboratório.

### 2 - SISTEMAS NÃO-LINEARES

Um sistema não-linear, contínuo no tempo, pode ser colocado na forma da seguinte equação:

$$\begin{aligned} \dot{x}(t) &= f(x(t), u(t)) \\ y(t) &= h(x(t)) \end{aligned} \quad (1)$$

onde  $x$  é a variável de estado que pertence a um conjunto aberto  $X$  de  $\mathbb{R}^n$ ;  $u$  é a variável de controle que pertence a um conjunto aberto  $U$  de  $\mathbb{R}^m$ ;  $y$  é a saída do sistema que pertence a um conjunto aberto  $Y$  de  $\mathbb{R}^p$ ;  $t$  é a variável independente representando o tempo contínuo;  $f$  é um mapeamento suave de  $\mathbb{R}^{m+n}$  para  $\mathbb{R}^n$ , e  $h$  é também um mapeamento suave de  $\mathbb{R}^n$  para  $\mathbb{R}^p$ . Esta é uma classe de sistemas bastante geral porque somente se aplica a restrição de que  $f$  e  $h$  sejam suaves. O estabelecimento de um procedimento geral para o controle de tais sistemas é uma tarefa bastante complexa. A maioria dos procedimentos seriam altamente dependentes das características de  $f$  e  $h$ . Além do mais, a abrangência do esquema de controle estaria restrita aos conjuntos  $X$ ,  $Y$ , e  $U$ .

Alguns procedimentos de controle consideram sistemas da seguinte classe:

$$\begin{aligned} \dot{x}(t) &= f(x(t)) + \sum_{i=1}^m g_i(x(t)) u_i(t) \quad (2) \\ y(t) &= h(x(t)) \end{aligned}$$

onde  $x$  é a variável de estado pertencente a um conjunto aberto  $X$  de  $\mathbb{R}^n$ ;  $u$  é a variável de controle pertencente a um conjunto aberto  $U$  de  $\mathbb{R}^m$ ;  $y$  é saída do sistema pertencente a um conjunto aberto  $Y$  de  $\mathbb{R}^p$  e  $t$  é a variável independente representando o tempo contínuo. Neste caso,  $f$  e  $g_i$  são mapeamentos suaves de  $\mathbb{R}^n$  para  $\mathbb{R}^n$ ;  $h$  é também um mapeamento suave de  $\mathbb{R}^n$  para  $\mathbb{R}^p$ . Esta é uma classe mais restrita de sistemas, visto que, algumas plantas industriais somente podem ser colocadas na forma da equação (1). O método de linearização por realimentação [4] é um exemplo de procedimento que exige que o sistema esteja na forma da equação (2). Problemas importantes, tais como a determinação da controlabilidade [6] e desacoplamento de entrada-saída [7], foram analisados para essas classes de sistemas. A solução do problema de linearização por realimentação para sistemas não-identificados da classe (1) foi proposto em [4]. O problema da identificação foi tratado em [9], usando redes neurais de várias camadas.

No caso específico, deste trabalho, não é possível enquadrar o sistema implementado em laboratório na classe (2), devido à consideração do retificador controlado e da carga constituída

pelo gerador de indução. Assim sendo, deve-se enquadrá-lo na classe (1), que é uma classe mais geral de sistemas não-lineares.

### 3 - O SISTEMA DINÂMICO

O sistema dinâmico estimado é composto por um motor C.C. de 220 volts / 370 watts acoplado a um gerador de indução, também de 220 volts / 370 watts, ligado a uma carga capacitiva de 10  $\mu$ F. O motor C.C. é alimentado por um retificador trifásico de 6 pulsos a tiristor. A tensão fornecida pelo retificador ao motor é dependente do ângulo de disparo dos tiristores. Este ângulo é fornecido pelo computador em forma binária que é então convertido em um nível de tensão analógica por um conversor digital / analógico de 8 bits. Esta tensão é aplicada ao circuito gerador de disparo que a utilizara como referência para geração de ângulo de disparo. É importante destacar que o retificador trifásico é, por si só, um sistema não-linear já que a relação entre a tensão de saída do retificador e o ângulo de disparo é senoidal. De acordo com o exposto, a tensão aplicada à armadura do motor C.C. é dependente do ângulo de disparo fornecido pelo computador, o que garante um controle total da excitação do motor C.C.. A realimentação, isto é, a leitura da velocidade de rotação do motor é realizada por um medidor ótico de velocidade acoplado ao eixo do motor. Este medidor fornece uma tensão C.C., proporcional a velocidade de rotação do motor. Um conversor analógico / digital de 8 bits converte esta tensão em um número binário que é lido pelo computador. O computador controla as informações sobre o comportamento do sistema, a qualquer instante, através do circuito de realimentação e excitação. Utilizou-se o tempo mínimo de amostragem igual a 130 ms. Este tempo de deve aos atrasos inerentes aos dispositivos de medida.

Na seção seguinte descreve-se a rede neural usada na estimação da dinâmica do conjunto.

### 4 - TREINAMENTO DA REDE NEURAL

Para a estimação da dinâmica direta do sistema dinâmico, foi utilizada uma rede neural do tipo Perceptron com uma camada

intermediária. A camada de entrada é formada por 10 elementos, a camada intermediária por 350 elementos e a camada de saída por 1 elemento. O algoritmo de treinamento utilizado foi o de Propagação Retroativa [11]. Os seguintes passos são seguidos para o treinamento da rede neural.

1) Apresentam-se, à entrada da rede, as 4 últimas velocidades lidas do motor C.C. e o ângulo de disparo que é também enviado ao retificador. Este ângulo é gerado aleatoriamente pelo computador com distribuição uniforme de probabilidade. Isto garante um aprendizado uniforme dentro da região de operação.

2) Calcula-se a saída da camada intermediária com a seguinte equação:

$$h_k = \frac{1}{1 + e^{-\sum_i v_{ik} s_i}} \quad (3)$$

onde:

$V_{ik}$  = Matriz de pesos entre a camada de entrada e a intermediária.

$S_i$  = Camada de entrada.

3) Calcula-se a saída da rede com a seguinte equação:

$$u_j = \frac{1}{1 + e^{-\sum_k w_{kj} h_k}} \quad (4)$$

onde:

$W_{kj}$  = Matriz de pesos entre a camada intermediária e a de saída.

$h_k$  = Saída da camada intermediária.

4) Calcula-se o valor de  $\delta_j$  a ser utilizado na atualização da matriz de pesos  $W_{kj}$ .

$$\delta_j = u_j (1 - u_j) (t_j - u_j) \quad (5)$$

onde:

$u_j$  = Saída da rede.

$t_j$  = Valor desejado para a saída da rede, que no caso é a velocidade atual de rotação do motor.

5) Calcula-se o valor de  $\Delta W_{kj}(n)$  a ser

adicionado à matriz de pesos  $W_{kj}$ .

$$\Delta w_{kj}(n) = \eta \delta_j h_k + \alpha \Delta w_{kj}(n-1) \quad (6)$$

onde:

$\eta$  = Taxa de aprendizagem.

$\delta_j$  = Erro entre o valor desejado e o obtido na saída da rede.

$\alpha$  = Fator de amortecimento.

$\Delta W_{kj}(n-1)$  = Último valor adicionado à matriz de pesos  $W_{kj}$ .

No projeto em questão os valores escolhidos para  $\eta$  e  $\alpha$  são:

$$\eta = 0.05$$

$$\alpha = 0.0$$

6) Calcula-se o valor de  $\delta_k^*$  a ser utilizado na atualização da matriz de pesos  $V_{ik}$ .

$$\delta_k^* = h_k (1 - h_k) \sum_j \delta_j w_{kj} \quad (7)$$

7) Calcula-se o valor de  $\Delta V_{ik}(n)$  a ser adicionado à matriz de pesos  $V_{ik}$ .

$$\Delta v_{ik}(n) = \eta \delta_k^* s_i + \alpha \Delta v_{ik}(n-1) \quad (8)$$

onde:

$\Delta V_{ik}(n-1)$  = Último valor adicionado à matriz de pesos  $V_{ik}$ .

8) Atualizam-se as matrizes de pesos  $W_{kj}$  e  $V_{ik}$  com os valores  $\Delta W_{kj}$  e  $\Delta V_{ik}$ , respectivamente.

9) Repetem-se os passos de 1 a 8 por aproximadamente 1.000 vezes, e a partir daí a rede é colocada no modo de reconhecimento onde seu desempenho é avaliado.

Na figura 1 tem-se um diagrama de blocos para o treinamento da rede.

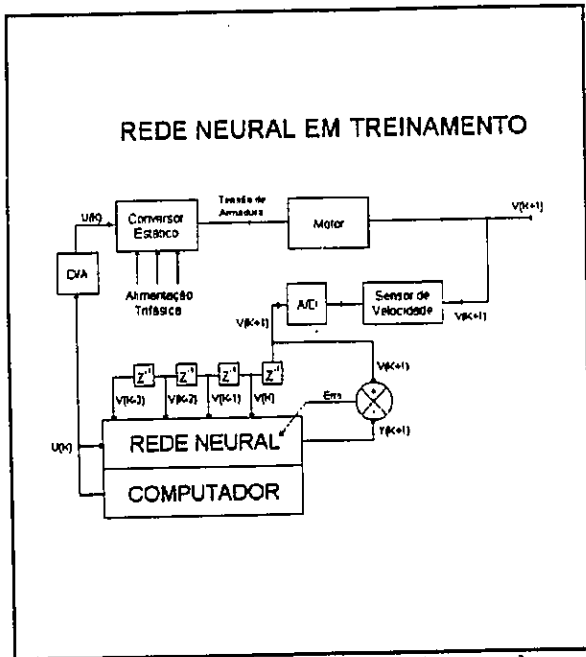


Fig. 1 - Treinamento da rede neural

### 5 - OPERAÇÃO DA REDE NEURAL

A figura 2 apresenta um diagrama de blocos de todo o sistema, com a rede neural no modo de operação.

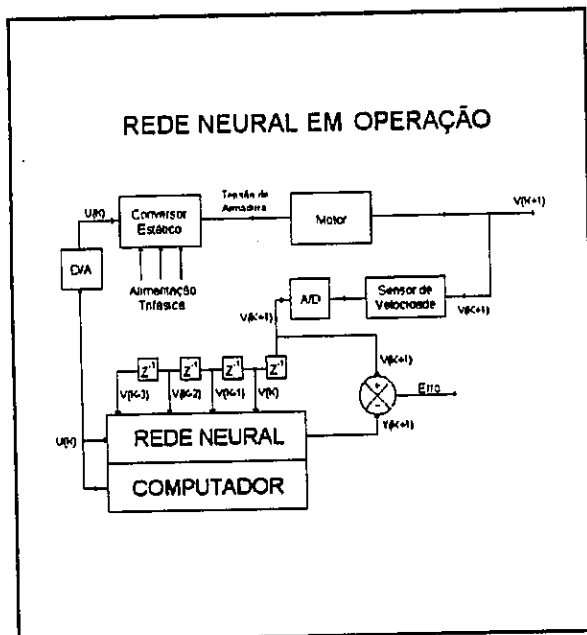


Fig. 2 - Rede neural em operação

Neste modo, a camada de entrada da rede é excitada com o ângulo de disparo atual, que também é fornecido ao retificador, e as 4 últimas velocidades anteriormente lidas do motor. A saída da rede será a próxima velocidade de rotação do motor para o ângulo de disparo atual.

Assim, esta velocidade, juntamente com a velocidade atual, lida do motor, são mostradas em um gráfico, onde é feita uma comparação entre as mesmas. Se o resultado ainda não atingiu a precisão desejada a rede é novamente colocada no modo de treinamento.

### 6 - RESULTADOS

Após decorridas 1000 iterações, o processo de treinamento da rede neural foi interrompido para avaliar-se o desempenho da mesma. Para isto, a rede foi colocada no modo de operação e a partir daí, foram armazenadas as velocidades apresentadas pela rede neural e pelo motor C.C., para as mesmas excitações. A figura 3 mostra o gráfico com as referidas velocidades.




Fig. 3 - Resposta da rede neural após 1000 iterações

Observa-se que, com apenas 1000 sessões de treinamento a rede neural não consegue acompanhar a velocidade apresentada pelo motor C.C., cometendo erros absurdos. Face a isto, a rede foi colocada no modo de treinamento até 7000 iterações. Neste ponto, a rede foi novamente colocada no modo de operação para avaliar-se o seu desempenho. A figura 4 mostra a resposta da rede neural após esta segunda seção de treinamento. Na figura, observa-se que a resposta de velocidade da rede já se aproxima muito da velocidade do motor

C.C.. O erro cometido pela rede, neste caso, é muito menor que o observado após 1000 iterações.

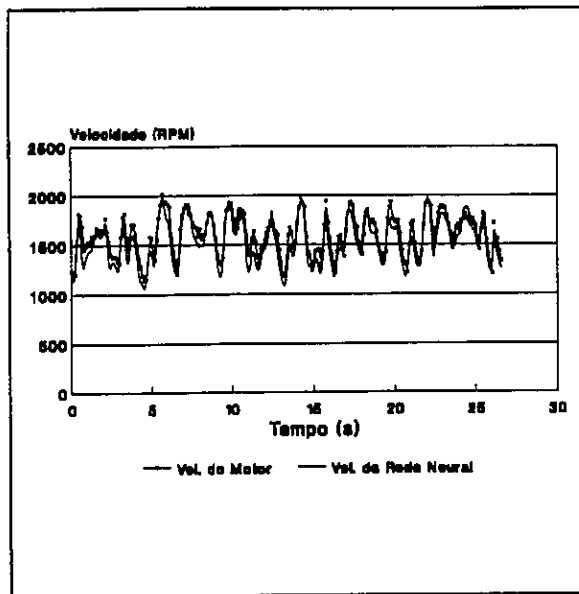


Fig. 4 - Resposta da rede neural após 7000 iterações

Como houve uma grande melhoria na assimilação das características do sistema não-linear, com esta segunda seção de treinamento, a rede foi novamente colocada no modo de treinamento. Desta vez, após 18000 e 25000 iterações, o seu desempenho foi avaliado, obtendo-se os mesmos resultados, conforme mostrado na figura 5.




Fig. 5 - Resposta da rede neural após 25000 iterações.

Neste ponto, a rede neural praticamente já assimilou todas as características do sistema a ela conectado e o erro manteve-se a um valor máximo de 30 RPM.

## 7 - CONCLUSÃO

Os resultados obtidos experimentalmente em laboratório mostram que a rede neural aprendeu a dinâmica direta do sistema com muita exatidão. Deve-se salientar que os testes foram feitos em laboratório utilizando-se equipamentos comuns no mercado, o que viabiliza a sua aplicação prática. Embora tenha-se utilizado um computador IBM 486 para treinamento da rede, pretende-se em um futuro próximo testar um circuito dedicado que está sendo desenvolvido em nosso laboratório. Está sendo também implementado o processo de linearização por realimentação desenvolvido em [4] e que será apresentado em uma próxima publicação.

## 8 - REFERÊNCIAS

- [1] Rumelhart, D. McClelland, J., "Parallel Distributed Processing", Vol. 1, MIT Press, Cambridge, MA, 4<sup>th</sup> Edition, 1987.
- [2] Loparo K. & Teixeira E., "A new approach For Adaptive Control of Nonlinear Systems Using Neural Networks", IEEE Int. Conf. Sys. Man Cyb., Los Angeles, 1990.
- [3] Teixeira E, Loparo K, Gomide F, "Design Multi-layer Neural Networks for Accurate Identification of Nonlinear Mappings", American Cont C., Boston, 1991.
- [4] Teixeira E., Loparo K., Gomide F., "Feedback Linearization of Dynamic Nonlinear Systems Using Neural Networks", 9º Cong. Bras. Autom., Vitória, 1992.
- [5] Nie J. & Linkens D., "Neural Network-based approximate reasoning: principles and implementation", Int. Journal of Control, vol. 56, nº 2, pp. 399-413, 1992.
- [6] Stefani G. "On the Local Controllability of a Scalar-Input Control System", Theory and Application of Nonlinear Control Systems, Elsevier Science, 1986.

- [7] Singh R. & Rugh W. "Decoupling Class of Nonlinear Systems by State Variable Feedback", Transactions ASME J.D.Syst.M.Cont, V.21, pp. 651-654, 1975.
- [8] Nguyen D. & Widrow B. "Neural Networks for Self-Learning Control Systems", IEEE Control Magazine Systems, April 1990.
- [9] Narendra, K., Parthasarathy, K. "Identification and Control of Dynamical Systems Using Neural Networks", IEEE Transactions on Neural Networks, Vol.1, #1, March 1990.
- [10] Oliveira, S. R. J. & Teixeira, E. P. "Identificação da Dinâmica Inversa de Sistemas Não-Lineares Através de Redes Neurais Artificiais", I SBAI - UNESP Rio Claro, Setembro 1993.
- [11] David, J. B. "Experiments on Neural Net Recognition of Spoken and Written Text", IEEE Transactions on Acoustics, Speech, and Signal Processing, Vol. 36, #7, July 1988.