

Controle Linearizante de Servomecanismo Utilizando Redes Neurais Artificiais*

J. F. Haffner, N. T. Meyrer, J. N. Amaral and L. F. A. Pereira

Programa de Pós-Graduação em Engenharia Elétrica
Pontifícia Universidade Católica do Rio Grande do Sul

<http://www.ee.pucrs.br>

90619-900 - Porto Alegre - RS - Brasil

Resumo

A Linearizing Control (LC) is used to train a Multi Layer Perceptron (MLP) in the task of controlling a DC motor with a non-linear load. After training the MLP replaces the LC and yields significantly better performance even in presence of noise and model mismatch.

1 Introdução

Este artigo estuda o controle de posição de um servomecanismo com carga não-linear aplicada ao eixo de um motor de corrente contínua. A aplicação de um Controle Linearizante (CL) é comparada com uma rede do tipo MLP (Multi Layer Perceptron). A técnica de CL é muito utilizada no controle de *tracking*, porém ela apresenta algumas limitações: não garante robustez quando existem incertezas nos parâmetros da planta ou quando existem dinâmicas não modeladas; e a sua aplicação demanda a medição de todos os estados da planta [4].

A substituição de um CL com uma MLP para este problema visa explorar as características principais destas redes: robustez na presença de ruído; capacidade de generalização; e capacidade de aproximar funções não lineares [3]. Neste trabalho um CL é utilizado para gerar os dados de treinamento da MLP. Após o treinamento, o CL é removido do sistema e a MLP passa a realizar a sua função. Nossos resultados de simulação indicam que a utilização da MLP resultou em um controle robusto na presença de distúrbios de carga, ruído nos estados, e alteração dos parâmetros do motor.

*Este trabalho foi financiado em parte pela Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela Fundação de Apoio à Pesquisa do Estado do Rio Grande do Sul (FAPERGS) e pela Pontifícia Universidade Católica do Rio Grande do Sul (PUCRS).

2 Modelo do Servomecanismo

O servomecanismo empregado neste trabalho consiste de um motor CC de imã permanente cujo eixo possui uma caixa de redução, a essa redução está conectada uma haste em ângulo de noventa graus e na extremidade desta haste uma massa. O conjunto haste e massa resulta em uma carga não linear aplicada ao eixo do motor. O estudo de simulação considera que a redução de velocidade é ideal; a carga está concentrada em um ponto e o peso da haste é desprezível. O modelo do servomecanismo pode ser descrito em variáveis de estado, conforme equações a seguir. As variáveis são definidas como: x_1 posição, x_2 velocidade e x_3 corrente de armadura. A entrada de controle u corresponde a tensão de armadura (E_a). Para realizar o controle deste servomecanismo propomos um controle linearizante com o uso de um modelo de referência e realimentação de estados como apresentado em [4]. O distúrbio de torque não é considerado.

$$\mathbf{x} = [x_1 \ x_2 \ x_3]^T$$

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \\ \dot{x}_3 \end{bmatrix} = \begin{bmatrix} \frac{g}{l} \text{sen}(x_1) - \frac{B}{J} x_2 + \frac{k_i N}{J} x_3 \\ -\frac{k_b N}{L_a} x_2 - \frac{R_a}{L_a} x_3 \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ \frac{1}{L_a} \end{bmatrix} u + \begin{bmatrix} 0 \\ \frac{-N}{J} \\ 0 \end{bmatrix} d$$

$$y = [1 \ 0 \ 0] \mathbf{x} \quad (1)$$

3 Controle Linearizante com RNA

Pode-se demonstrar que no CL/RNA a rede deve reproduzir a ação de controle definida em 2, onde \mathbf{y} é o vetor composto por posição, velocidade e aceleração [1]. O termo $f(\mathbf{y})$ serve para cancelar as não-linearidades inseridas no modelo e o termo ϑ é efetivamente a ação de controle que faz o sistema comportar-se de acordo com o modelo de referência. Para treinamento necessitamos de um conjunto de dados compostos por $[y \ \dot{y} \ \ddot{y} \ y_m \ \dot{y}_m \ \ddot{y}_m \ u]$. Assumindo $[y \ \dot{y} \ \ddot{y} \ y_m \ \dot{y}_m \ \ddot{y}_m]$ como as entradas da RNA e u como a saída desejada, treina-se a rede com o conjunto de dados. Quando o erro na saída for mínimo, a rede constitui uma boa aproximação da ação de controle fornecida na equação 2. Como no controle inverso não-linear com RNA (INC/NN) descrito em [2], utilizamos nessa entrada a lei de controle descrita na equação 3.

$$u = \frac{1}{C}(\vartheta - f(\mathbf{y})) \quad (2)$$

$$f(\mathbf{y}) = \frac{g}{l} \text{sen}(y) \left(\frac{R_a}{L_a} - \frac{B}{J + ml^2} \right) + \frac{B}{J + ml^2} \dot{y} \left(1 - \frac{k_i k_b N^2}{L_a B} - \frac{R_a}{L_a} \right) - \frac{R_a}{L_a} \ddot{y}$$

$$\mathbf{y} = [y \ \dot{y} \ \ddot{y}]^T$$

$$\ddot{y}_e = \ddot{y}_m + K_1(\dot{y}_m - \dot{y}) + K_2(y_m - y) \quad (3)$$

Considerando as características mecânicas e elétricas do servomecanismo utilizado, construímos um modelo de referência de segunda ordem $[y_m \dot{y}_m \ddot{y}_m]$. O CL/RNA consiste de uma RNA que aproxima a equação 2, um modelo de referência e uma escolha adequada de K_1 e K_2 para controle em malha fechada. O diagrama em blocos do CL/RNA é mostrado na Figura 1.

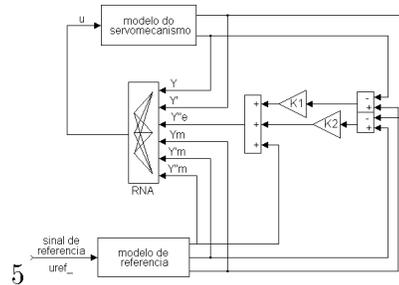


Figura 1: Controle Linearizante com RNA

Para geração dos dados de treino, um ruído é injetado no sinal de controle com a finalidade de provocar uma excitação persistente [5]. A relação entrada/saída do sistema dinâmico é usada para treinar uma MLP com seis entradas, uma camada escondida de 25 neurônios e uma saída. Para treinamento foi utilizada a função *trainlm* do MATLAB. Esta função utiliza o algoritmo de Levenberg-Marquardt. Utilizamos um ruído gaussiano de média zero e variância dois, e trinta segundos de sinal pseudo-aleatório para obter o conjunto de treino e teste.

4 Resultados Obtidos

Para simulação utilizamos o SIMULINK com incremento de integração de 1 ms . Os dados do motor foram tirados do catálogo da PITTMAN ref.GM9234. Os principais dados são: R_a resistência de armadura $0,83\Omega$; L_a indutância de armadura $0,63\text{mH}$; k_t constante de torque $0,0182\text{Nm A}^{-1}$; k_b constante de fcm $0,0182\text{V s rad}^{-1}$; J momento de inércia $8,32\text{e-}6\text{Kg m}^2$; B coeficiente de atrito viscoso $9,0\text{e-}4\text{Nm s/rad}$; N relação de redução $5,9$; E_a tensão de armadura, 12V nominal; I_a corrente de armadura. Os valores da carga são: l comprimento da haste $0,2\text{m}$; m massa da esfera $0,2\text{kg}$; g força gravitacional $9,8\text{ ms}^{-2}$.

A Figura 2 apresenta alguns dos resultados de nossas simulações. Os gráficos da esquerda comparam o CL com o CL/RNA com ruído injetado na tensão de controle. Foi utilizado um ruído gaussiano de média zero e variância um. A parte (b) da Figura 2 faz comparação similar, porém com alteração dos parâmetros R_a e L_a do motor. A variação utilizada ficou próxima a doze por cento. É possível notar em ambas que no CL a saída do servomecanismo sofre influência destas alterações, o mesmo não ocorre no CL/RNA. Resultados considerando distúrbios de carga são apresentados em [1].

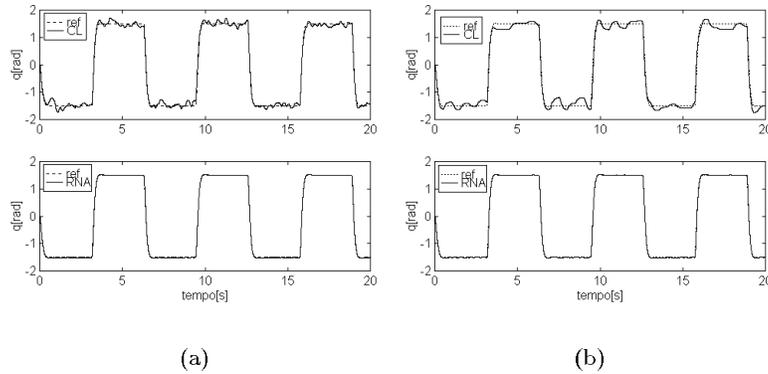


Figura 2: Comparação entre o CL e o CL/RNA: (a) com ruído nos estados; (b) com variação nos parâmetros R_a e L_a do motor CC.

5 Conclusões

A RNA utilizada, substituiu o CL suprimindo justamente as deficiências deste. O controle tornou-se robusto na presença de ruído, com alteração nos parâmetros da planta e mesmo na presença de dinâmica não modelada. É importante ressaltar que a combinação CL/RNA dispensou a medida da corrente de armadura x_3 . Foi possível realizar o controle apenas a partir da informação de posição x_1 e velocidade x_2 . Esta é uma grande vantagem devido à necessidade de utilização de sensores de precisão para medir a corrente de armadura quando apenas o CL é utilizado. A medição de posição pode ser obtida por um simples *encoder*. A velocidade pode ser obtida a partir deste.

Referências

- [1] J. F. Haffner, N. Meyrer, J. N. Amaral, and L. F. A. Pereira. A multilayer perceptron replaces a non-linear servomechanism controller. In preparation, to be submitted to the 1998 International Conference on Neural Network.
- [2] J.F. Haffner, N.T. Meyrer, J.N. Amaral, and L.F.A. Pereira. Utilização de redes neurais artificiais para controle de posição de servomecanismo com carga não-linear. In *III Congresso Brasileiro de Redes Neurais*, pages 455–460, Florianópolis, 1997. L. Caloba and J. Barreto.
- [3] T. S. Low, T. H. Lee, and H. K. Lim. A methodology for neural network training for control of drives with nonlinearities. *IEEE Trans. Ind. Electronics*, 39(2):243–249, April 1993.
- [4] J.J.E. Slotine and W. Li. *Applied Nonlinear Control*. Prentice-Hall Inc., 1991.
- [5] R.S. Sutton and P.J. Werbos. *Neural networks for control*. MIT Press, London, 1995.