

Utilização de Redes Neurais Artificiais para Controle de Posição de Servomecanismo com Carga Não-linear*

José Felipe Haffner
jfelipe@ee.pucrs.br

Ney Meyrer
meyrer@ee.pucrs.br

José Nelson Amaral
amaral@ee.pucrs.br

Luís Fernando Alves Pereira
pereira@ee.pucrs.br

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

Neste artigo um controle inverso não-linear com rede neural artificial foi utilizado para controle de posição de um motor de corrente contínua com carga não-linear aplicada ao eixo. Utilizando treinamento em malha fechada, a rede foi treinada para reproduzir a dinâmica inversa do sistema. Resultados de simulação indicam que um MLP que recebe também os valores atrasados das medidas de posição, velocidade e aceleração em suas entradas possui melhor performance quando utilizada no controle não linear.

Abstract

In this paper an Inverse Nonlinear Control with Neural Networks is used to control the position of a CC motor to which a nonlinear load is applied. Using data obtained from a closed loop system, the ANN is trained to reproduce the inverse dynamic of the system. Our simulation results indicate that a MLP that also receives as

*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).

input delayed values of the position, speed and acceleration of the motor yields better performance when used in the nonlinear control.

Keywords: MLP, Inverse Nonlinear Control, CC motor control.

1 Introdução

Este artigo aborda o problema de controlar a posição de um servomecanismo com carga não-linear aplicada ao eixo do motor de corrente contínua (CC). Uma revisão da literatura revela várias técnicas que podem ser utilizadas para o controle de servomecanismos. Ohishi *et al.* propõem a utilização de um observador de torque para estimar as forças externas, diminuindo o erro no transitório e em regime [5]. Esta técnica apresenta rápida convergência e alta robustez à variação de parâmetros, mas possui a desvantagem de ser muito sensível a ruídos nas medições de corrente e velocidade. Naitoh e Tadakuma utilizam Controle Adaptativo por Modelo de Referência (MRAC) para o controle de motores CC [3]. No entanto é difícil garantir a estabilidade de MRAC na presença de transitórios e perturbações.

Uma alternativa é a utilização de Redes Neurais Artificiais (RNA) para a identificação e o controle de servomecanismos. Algumas caracte-

terísticas de RNAs que as tornam atraentes para aplicações em controle são: capacidade de generalização; capacidade de aproximar funções não lineares; capacidade de aprendizado a partir de dados de treino, sem necessidade de construção de um modelo parametrizado da planta; robustez na presença de ruído [2]. A estrutura de RNAs mais utilizada em controle de sistemas é uma rede formada por perceptrons e organizada em múltiplas camadas denominada *MultiLayered Perceptrons* (MLP) [7].

Low *et al.* apresenta uma metodologia para o treinamento de MLPs para utilização em servossistemas com não-linearidades [2]. Neste controle a rede é treinada de forma a reproduzir a dinâmica inversa da planta, conhecido como *Inverse Nonlinear Control using Neural Network* (INC/NN). Eles propõem um treinamento em malha aberta e outro em malha fechada. No treinamento em malha aberta uma entrada randômica $u(t)$ é apresentada ao servomecanismo e as saídas de posição $q(t)$, velocidade $\dot{q}(t)$ e aceleração $\ddot{q}(t)$ são medidas. Estas saídas são apresentadas como entradas para um MLP cuja saída desejada é $u(t)$. O problema com este esquema de treinamento em malha aberta é que ele não consegue aproximar adequadamente a função inversa pretendida na presença de não linearidades.

Neste artigo utilizamos o segundo método proposto por Low *et al.* que utiliza uma estrutura em malha fechada com um controlador proporcional para obter os dados para treinamento da MLP [2]. A seção 2 apresenta o modelo do servomecanismo, a seção 3 apresenta a estrutura do controle inverso não linear, a seção 4 apresenta o treinamento da RNA, a seção 5 apresenta os resultados obtidos por simulação e a seção 6 apresenta algumas reflexões sobre o trabalho desenvolvido.

2 Modelo do Servomecanismo

Considerando o servomecanismo não linear descrito pela equação 1, utilizado por Low *et al.*

$$m(q, \dot{q})\ddot{q} + f(q, \dot{q}) = u \quad (1)$$

onde q representa a posição angular, \dot{q} a velocidade angular, \ddot{q} a aceleração, e u a tensão aplicada no motor [2, 1]. Assumimos que $m(.,.)$ e $f(.,.)$ são funções contínuas com $m(.,.) > 0$. O servomecanismo empregado neste trabalho consiste de um motor CC de imã permanente em cujo eixo está conectada uma haste em ângulo de noventa graus e na extremidade desta haste uma massa. Este conjunto haste e massa resulta em uma carga não linear aplicada ao eixo do motor. Para controlar o torque do motor inserimos uma realimentação da corrente de armadura para a entrada de referência. Para simular a não linearidade da carga representada pela haste e massa o modelo do sistema inclui uma função não linear $G(q)$ que relaciona a posição angular com o torque imposto pela carga. O modelo apresenta um redutor de velocidade entre o eixo do motor e a carga.

I_a	corrente de armadura	
E_a	tensão de armadura	
R_a	resistência de armadura	4,62 Ω
L_a	indutância de armadura	3,97 mH
K	ganho de realimentação de I_a	2,7
K_i	constante de torque	0,0459 NmA ⁻¹
K_b	constante de fcm	0,0459 V s rad ⁻¹
J	momento de inércia	8,32 e-6 Kg m ²
B	coeficiente de atrito viscoso	5,22 e-6 Nms/rad
N	relação de redução	11,5

Tabela 1: Dados do motor

O modelo do servomecanismo é descrito pelas Equações 2 e 3. A descrição dos símbolos e os valores utilizados para cada um dos parâmetros nas simulações apresentadas na seção 5 encontram-se na Tabela 1.

$$\dot{I}_a = \frac{(R_a + K)}{L_a} I_a - \frac{K_b N}{L_a} \dot{q} + \frac{E_a}{L_a} \quad (2)$$

$$\ddot{q} = \frac{K_i N}{J} G(q) I_a - \frac{B}{J} \dot{q} - \frac{T_D}{J} \quad (3)$$

Neste artigo utilizamos a curva característica da não-linearidade da carga apresentada na Figura 1. Em nossas simulações¹ a função representada por esta curva foi aproximada por uma MLP com uma única camada escondida formada por seis neurônios.

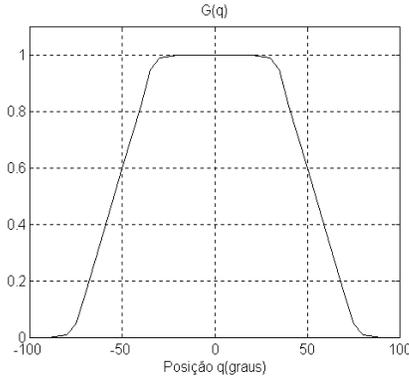


Figura 1: Curva característica da não-linearidade da carga

3 Controle Inverso Não-linear com RNA

No INC/NN, a RNA deve reproduzir a dinâmica inversa da planta. Para treinamento necessitamos de um conjunto de dados composto por $[q(t), \dot{q}(t), \ddot{q}(t), u(t)]$.

Assumindo $[x_1, x_2, x_3] \equiv [q, \dot{q}, \ddot{q}]$ 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 dinâmica inversa do servomecanismo descrito por 1. A RNA aproxima a função

$$u = N_1(x_1, x_2, x_3) = \hat{m}(x_1, x_2)x_3 + \hat{f}(x_1, x_2) \quad (4)$$

Considerando a RNA como uma aproximação acurada do sistema, i.e. $m(.,.) = \hat{m}(.,.)$ e $f(.,.) = \hat{f}(.,.)$, utiliza-se a lei de controle [2]

$$x_1 = q \quad (5)$$

$$x_2 = \dot{q} \quad (6)$$

$$x_3 = \ddot{q}_{ref} + K_1(\dot{q}_{ref} - \dot{q}) + K_2(q_{ref} - q) \quad (7)$$

Os valores de posição (q) e velocidade (\dot{q}) podem ser lidos diretamente na saída da planta. Considerando as características mecânicas e elétricas do servomecanismo utilizado, construímos um modelo de referência de segunda ordem $[q_{ref}, \dot{q}_{ref}, \ddot{q}_{ref}]$. O INC/NN consiste de uma RNA que aproxima a equação 4, um modelo de referência e uma escolha adequada de K_1 e K_2 para o controle em malha fechada. O diagrama em blocos do INC/NN é mostrado na Figura 2.

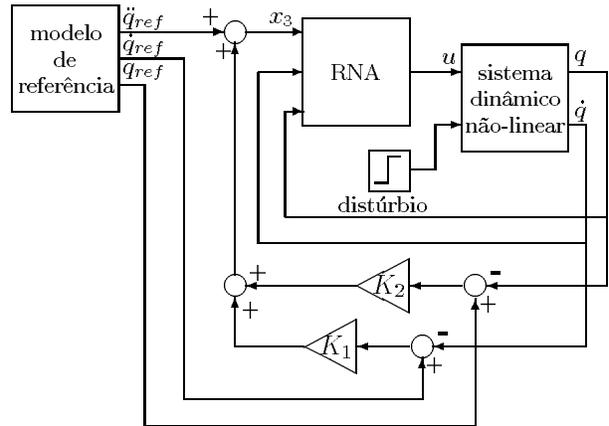


Figura 2: Controle Inverso Não-linear com RNA

¹motor e redutor

4 Treinamento da RNA

Necessitamos treinar uma MLP para aproximar a dinâmica inversa do servomecanismo e incorporar a ação de controle. Os sinais utilizados no treinamento da RNA são $q(t)$, $\dot{q}(t)$, $\ddot{q}(t)$ e $u(t)$. Para obter os dados de treinamento para a MLP, utilizamos o sistema realimentado com um controlador proporcional mostrado na Figura 3 [2]. O controlador proporcional P tem a finalidade de ajustar a posição angular no curso desejado. É necessário utilizar uma referência de posição suficientemente rica de forma a varrer toda a região de operação. Um sinal de ruído gaussiano $u_r(t)$, foi somado na entrada do sistema dinâmico não-linear. O sinal $u_r(t)$ serve para prover uma excitação persistente, que garante a generalidade do sinal de entrada $u(t)$ [6].

A ferramenta utilizada para simulação foi o SIMULINK, com um período de amostragem de $1ms$. No esquema para geração de dados apresentado na Figura 3, foi utilizado um ganho proporcional $P = 12$ e um ruído gaussiano de média zero e variância cinco. Um sinal pseudo-aleatório de $15s$ de duração, foi apresentado ao sistema dinâmico e os valores de q , \dot{q} , \ddot{q} e u_d armazenados em um arquivo de dados.

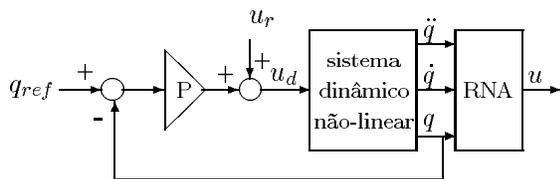


Figura 3: Treinamento em malha fechada

A MLP utilizada neste trabalho possui três entradas, uma única camada escondida com 50 neurônios e uma saída. Para treinamento foi utilizado o algoritmo de propagação reversa do erro, com atualização dos pesos sinápticos após a apresentação de cada ponto do conjunto de treino. Um ponto do conjunto de treino é formado pelos

valores das entradas do MLP ($q(t)$, $\dot{q}(t)$, $\ddot{q}(t)$) e pelo valor da saída desejada $u_d(t)$ determinada a partir da simulação ilustrada na Figura 3.

A estrutura de RNA descrita acima é similar a proposta por Low *et al.* [2]. Em nossas simulações esta rede somente conseguia aproximar o inverso da planta após um longo tempo de treinamento. Para permitir a identificação das características dinâmicas do servomecanismo passamos a utilizar uma segunda estrutura de RNA em que além das entradas $q(t)$, $\dot{q}(t)$ e $\ddot{q}(t)$ são também fornecidas como entrada $q(t-1)$, $\dot{q}(t-1)$ e $\ddot{q}(t-1)$. Nesta segunda estrutura de RNA também utilizamos uma única camada escondida formada por 50 neurônios.

A diferença entre a qualidade dos resultados obtidos com a RNA com apenas três entradas e com a RNA com as seis entradas é mostrada nos gráficos da Figura 4.

5 Resultados Obtidos

Em nossa simulação usamos o sistema descrito pelas Equações 2 e 3 com os dados de catálogo do motor PITTMAN GM9234, tensão nominal 30V e torque de pico 0,3 Nm apresentados na Tabela 1, e a curva de torque apresentada na Figura 1.

A rede treinada foi inserida no controle da Figura 2 e uma onda quadrada foi utilizada como referência. Um distúrbio de carga de 0,02 Nm foi aplicado em $t = 5s$. Os valores utilizados para K_1 e K_2 são respectivamente 200 e 30000. A rede sem elementos de atraso acompanha o sinal de referência, porém é possível notar oscilações e erro em regime após a entrada do distúrbio de carga. Já a rede com elementos de atraso mostrou-se superior nestas condições. Os resultados são apresentados nas Figuras 5 e 6.

6 Discussão

Uma das limitações da solução proposta em [2] e usada neste artigo é que o modelo utiliza

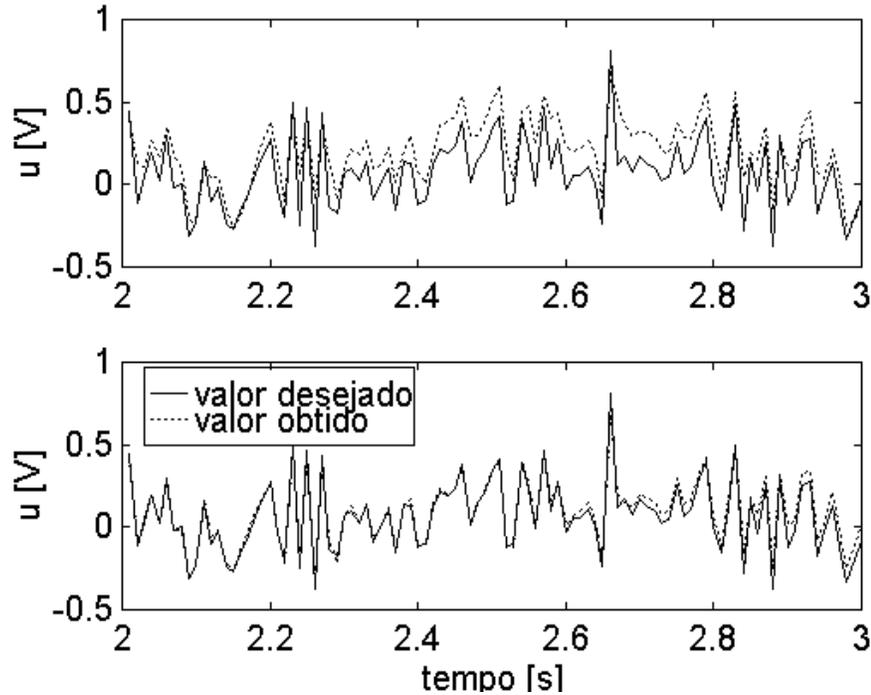


Figura 4: Comparação entre o sinal de controle gerado pela RNA $u(t)$ e o sinal desejado $u_d(t)$: (a) rede com três entradas ($q(t)$, $\dot{q}(t)$ e $\ddot{q}(t)$). (b) rede com seis entradas ($q(t)$, $\dot{q}(t)$, $\ddot{q}(t)$, $q(t-1)$, $\dot{q}(t-1)$, $\ddot{q}(t-1)$).

uma relação fixa entre o motor e a carga conectada ao eixo do mesmo. Esta relação é representada pela curva da Figura 1. Esta curva considera, por exemplo, que para uma determinada posição angular da carga o torque do motor é consumido na sua totalidade. Esta situação não poderia ocorrer em um sistema real. No esquema apresentado também é impossível que a carga dê uma volta completa no eixo do motor.

Uma alternativa para evitar a construção de uma solução específica para uma determinada carga é construir um modelo para todo o sistema incluindo motor e carga. Estamos trabalhando em um novo método de treinamento do sistema que inclui um modelamento de todo o sistema e elimina estas limitações.

Na geração dos dados para o treinamento da RNA neste trabalho utilizou-se um controlador proporcional que é adequado para o motor

simulado. No entanto este controlador não será satisfatório para motores de maior potência. Para resolver este problema estamos propondo a utilização de um controle por modelo de referência também para a geração dos dados. Estamos trabalhando no desenvolvimento de um modelo de referência de terceira ordem para a obtenção dos dados de treino para a RNA.

7 Conclusões

O INC/NN mostrou-se eficaz para o controle de posição do servomecanismo não-linear e manteve-se estável mesmo na presença de significativos distúrbios de carga. A utilização de elementos de atraso na RNA permitiu uma melhor aproximação da dinâmica inversa do servomecanismo pela rede. Narendra havia observado que quanto maior o número de estados anteriores uti-

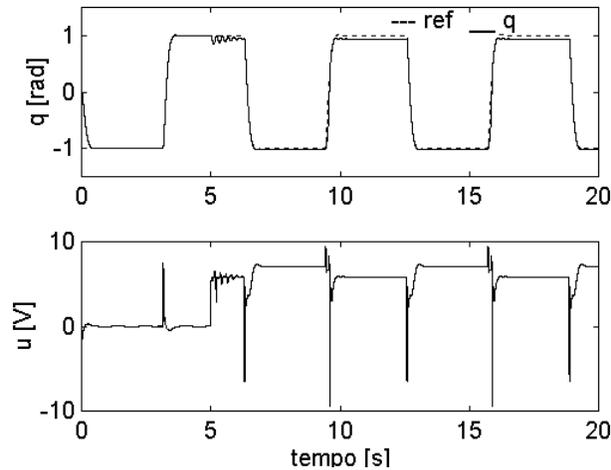


Figura 5: Resultados com a RNA com três entradas: (a) Sinal de referência de posição e saída $q(t)$ da planta; (b) sinal de controle gerado pela RNA.

lizados, melhor a aproximação do modelo inverso pela RNA, conforme apresentado por [4].

Neste artigo apresentamos uma nova abordagem para o treinamento de uma RNA a ser usada no controle inverso não linear de uma planta. Os resultados obtidos com nossas modificações são superiores aos publicados anteriormente por outros autores. Na continuação deste trabalho vamos melhorar o método de treinamento da rede construindo um modelo mais completo. Estamos também em fase adiantada no trabalho de implementar o sistema estudado até agora por simulação.

Referências

[1] T. H. Lee, W. K. Tan, and M. H. Ang Jr. A neural network control system with parallel adaptive enhancements applicable to nonlinear servomechanisms. *IEEE Transactions on Industrial Electronics*, 41(3):269–277, June 1994.

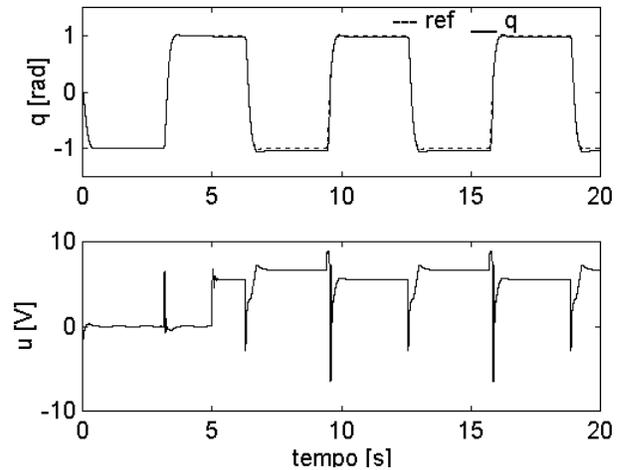


Figura 6: Resultados com a RNA com seis entradas: (a) Sinal de referência de posição e saída $q(t)$ da planta; (b) sinal de controle gerado pela RNA.

[2] 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.

[3] H. Naitoh and S. Tadakuma. Microprocessor-based adjustable-speed dc motor drives using model reference adaptive control. *IEEE Trans. Ind. Applications*, IA-23(2):313–318, March/April 1987.

[4] K. S. Narendra. Adaptive control of dynamical systems using neural networks. In D. A. White and D. A. Sofge, editors, *Handbook of Intelligent Control: Neural, Fuzzy, and Adaptive Approaches*, pages 141–183. Van Nostrand Reinhold, New York, 1992.

[5] K. Ohishi, M. Nakao, K. Ohnishi, and K. Miyachi. Microprocessor-controlled dc motor for load-insensitive position servo system. *IEEE Trans. Industrial Electronics*, 34(1):44–49, February 1987.

[6] R.S. Sutton and P.J. Werbos. *Neural networks for control*. MIT Press, London, 1995.

- [7] B. Widrow and E. Walach. *Adaptive Inverse Control*. Prentice Hall, Upper Saddle River, NJ, 1996.