

Identificação e Compensação de Atritos Não Lineares de Atuadores Robóticos Via Redes Neurais Artificiais

Vitor I. Gervini (ec2vig@super.furg.br)
Sebastião C. P. Gomes (dmtscpg@super.furg.br)
Fundação Universidade Federal do Rio Grande
Av. Itália, Km 8,
96201-900, Rio Grande, RS

Abstract

The knowledge of realistic dynamic models to robotic actuators would be of great aid in the conception of control laws for robot manipulators, mainly in the cases of the great precision robotic or still for manipulators with flexible links. In this paper we present a training strategy and propose a structure of Neural Network (NN) to learn the friction torque of a motor drive joint robotic actuator with gear. To train the NN it was used a friction model proposed in the literature (published in 1995). It was considered the motor torque and the rotor angular velocity as input in the NN, while the friction torque was the only output, which was used in the proposition of a non-linear friction compensation mechanism. The results attested the efficiency of the NN friction estimate and compensation with the proposed mechanism.

1. Introdução

Existem atualmente diversas aplicações de redes neurais artificiais (RNA), nos mais variados domínios da ciência e tecnologia [(Kaynak, and Ertugru, 1997), (Jung and Hsia, 1998)]. Trata-se de um assunto que tem merecido grande atenção por parte da comunidade científica. Em [Miller, 1995] tem uma importante descrição sobre o histórico das redes neurais artificiais.

Neste artigo investiga-se a possibilidade de identificação do torque de atrito de um atuador robótico do tipo moto-redutor, utilizando-se uma Rede Neural Artificial (RNA). A principal motivação reside na dificuldade de se encontrar um modelo dinâmico muito realista e preditivo para atuadores robóticos, dificuldade esta devida principalmente aos atritos não lineares internos aos atuadores [Armstrong, 1988]. Esta aplicação (identificação de atrito via RNA) começou a ser mais estudada apenas recentemente [(Dapper and Zanh, 1999), (Selmic and Lewis, 2000)], tratando-se, portanto, de um assunto bastante atual. Uma vez identificado o atrito não linear, propõe-se um mecanismo de compensação deste a fim de linearizar o atuador. A estratégia de identificação, utilizada

conjuntamente ao mecanismo de compensação, constitui a principal contribuição deste trabalho.

Como não se dispõe, até o presente momento, de um atuador robótico isolado em uma bancada a fim de se realizar experimentos, utilizou-se um modelo proposto na literatura [Gomes, 95]. Os resultados deste modelo serviram de referência como padrões de treinamento da RNA. A seqüência natural do presente trabalho será adquirir um moto-redutor do tipo *harmonic-drive* para a obtenção dos resultados experimentais, a fim de validar definitivamente o mecanismo de compensação de atritos proposto e testado em simulação. Como o modelo utilizado foi muito testado experimentalmente, acredita-se que todo o formalismo de identificação e compensação proposto deva proporcionar bons resultados na prática.

2. O Atuador Robótico

Um atuador robótico do tipo moto-redutor pode ser visualizado como um elemento transmissor de movimento contendo uma elasticidade interna de constante K , conforme representado na Fig. 1. O torque motor T_m é aplicado ao rotor de inércia I_r . Atritos não lineares estão sempre presentes neste tipo de dinâmica, fazendo com que o torque motor não seja transmitido integralmente à inércia I_s acoplada à saída do redutor. As equações (1) descrevem a dinâmica deste sistema [Gomes and Chrétien, 1992]. T_{at} corresponde ao torque de atrito não linear, o qual será obtido via RNA. θ_r e θ_s são, respectivamente, os ângulos do rotor e do eixo de saída do redutor.

$$\begin{aligned} I_r \ddot{\theta}_r + \frac{K}{n^2} (\theta_r - n\theta_s) &= T_m - T_{at} \\ I_s \ddot{\theta}_s - K \left(\frac{\theta_r}{n} - \theta_s \right) &= 0 \end{aligned} \quad (1)$$

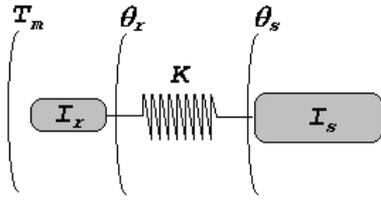


Figura 1. Representação de um atuador robótico do tipo moto-reductor.

O modelo para o torque de atrito utilizado foi publicado originalmente em [Gomes, 1995], tendo apresentado bons resultados quando feitas comparações entre experimentos e simulações. Este modelo reproduziu bem o fenômeno de *stick-slip*, notável por aparecer com frequência na prática. Este fenômeno foi definido em [Gomes, 1995] como tendo a seguinte origem: quando o torque resultante através do atuador está menor do que o atrito estático e ainda, a velocidade do rotor menor do que um certo valor limite que define a zona de *stiction* (intervalo de velocidade em torno do zero no qual ocorre o fenômeno), então a velocidade rotor vai a zero e assim permanece até que o torque resultante volte a ser superior ao atrito estático. Conforme será visto na seqüência deste trabalho, o modelo adotado reproduziu este fenômeno e a RNA o aprendeu bem.

3. O Mecanismo de Compensação

Apesar de ter se mostrado bastante eficiente, o mecanismo de compensação de atrito proposto no presente trabalho é simples, consistindo na rejeição direta do atrito não linear identificado pela RNA. Simulou-se o caso mais real de controle discreto, com um passo de discretização de 0.005 segundos. O torque motor no instante $k+1$ assume a forma:

$$T_m(k+1) = T_c(k) + \hat{T}_{nl}(k) \quad (2)$$

sendo $T_c(k)$ o torque de controle, o qual em malha fechada depende da observação do sistema no instante k . $\hat{T}_{nl}(k)$ é o atrito não linear estimado pela RNA (saída), tendo como entrada nesta a velocidade rotor $\dot{\theta}_r(k)$ e o torque motor $T_m(k)$.

4. Arquitetura da RNA

A arquitetura de rede adotada para a identificação do torque de atrito foi uma rede *backpropagation* (*multilayer, feedforward network, fully connected*) [Beale and Jackson, 1990]. Utilizou-se, como regra de treinamento, o *backpropagation com momentum*

[Fausett, 1994]. A camada de entrada foi composta de dois neurônios (torque motor e velocidade do rotor) e a camada de saída por um neurônio (torque de atrito).

Foi utilizada somente uma camada intermediária, tendo sido necessários apenas quatro neurônios nesta para aprender os padrões apresentados à rede. Foi testado um número maior de neurônios (8, 10, 16, 40 e outros), na camada intermediária, mas os resultados foram muito similares ao obtido com apenas 4 neurônios. Já que a arquitetura da RNA é muito pequena, isto a torna rápida e eficiente com um alto poder de generalização, permitindo assim uma compensação *online* do torque de atrito.

Na Fig.2 abaixo é mostrada a arquitetura da rede utilizada:

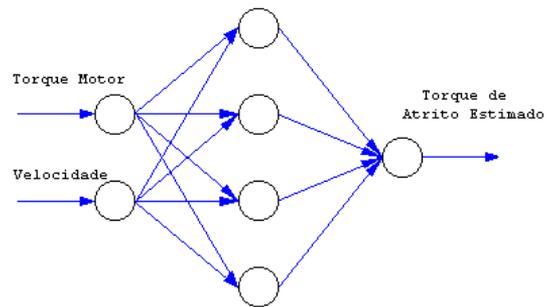


Figura 2 . Arquitetura da RNA.

A arquitetura dos neurônios é mostrada na Fig. 3, tendo-se utilizado uma função de ativação sigmoideal (*tanh*). Após o treinamento, a rede apresentou uma taxa de aprendizado de 98% dos padrões apresentados.

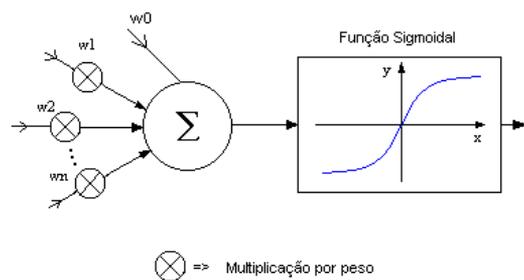


Figura 3. Arquitetura dos neurônios utilizada.

Na Fig. 4 mostram-se o torque motor e a velocidade rotor (entrada da rede), o torque de atrito do modelo (vermelho) e o torque de atrito reconhecido pela rede (preto). Pode-se perceber então que de fato, a taxa de aprendizado foi realmente elevada. Outro dado interessante é que se escolheu o torque motor de entrada formado a partir de seguimentos de senoides e degraus em malha aberta, além de alguns resultados em malha fechada obtidos com um controle proporcional e derivativo (últimos seguimentos em torque motor da Fig. 4). Esta diversificação do torque na estratégia de

treinamento foi importante para a generalização da RNA.

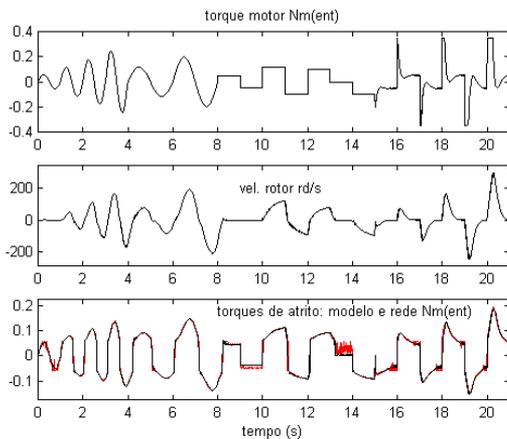


Figura 4. Padrões de treinamento da Rede.

5. Resultados de Simulações

Foram realizadas diversas simulações com dois objetivos principais: confrontar os resultados da saída da RNA com o modelo do torque de atrito não linear; testar a eficiência da estratégia de compensação do torque não linear de atrito a partir da identificação do mesmo via RNA.

O gráfico superior da Fig. 5 mostra o torque motor aplicado em malha aberta, composto de diversos seguimentos de senoides. A parte inferior mostra os torques de atrito do modelo e da RNA (em vermelho). Percebe-se que, de fato, a saída da RNA é praticamente coincidente com a curva obtida com o modelo.

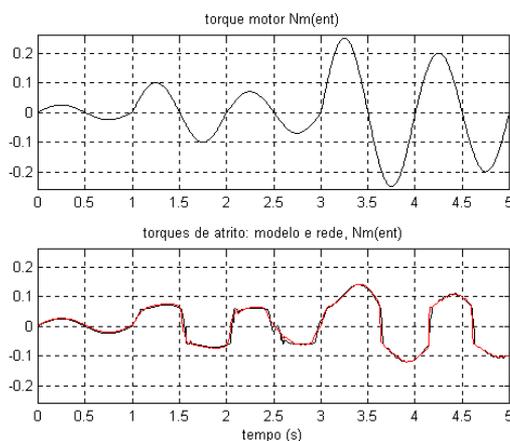


Figura 5. Torques, motor e de atritos.

Na Fig. 6 mostram-se os resultados da posição angular da saída do redutor, obtidas em três simulações distintas mas com o mesmo torque motor da Fig. 5: o caso linear (considerou-se apenas o atrito linear no modelo dinâmico - curva em vermelho); os casos não

linear com e sem a estratégia de compensação do torque de atrito. Pode-se perceber que a estratégia de compensação de atrito via RNA tende a linearizar a articulação, evitando de forma eficiente o fenômeno de *stick-slip* [Gomes, 1995], o qual é bastante visível na simulação com o atrito não linear e sem a compensação. Observar que há situações nas quais apesar da velocidade, na simulação com o atrito linear, estar diferente de zero, a velocidade na simulação com o atrito não linear permanece zero. Isto acontece porque, durante estes intervalos de tempo, o torque motor foi inferior ao atrito estático. Este é precisamente o conhecido modo *stick* [Armstrong, 1988]: a articulação se bloqueia e não há transmissão de movimento neste estado, apesar do torque motor ser diferente de zero.

Resultados semelhantes foram obtidos também em malha aberta para respostas ao degrau em torque (Figs. 7 e 8) e, assim como para o caso das senoides das Figs. 5 e 6, com amplitudes variadas e diferentes das que formaram os padrões de aprendizado da RNA. Os pequenos erros entre as simulações linear e não linear com compensação de atrito atestam a eficiência da estratégia de compensação proposta.

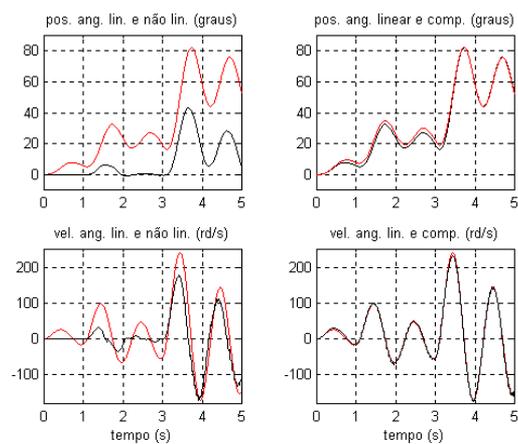


Figura 6. Posições e velocidades angulares (simulação com o atrito linear em vermelho).

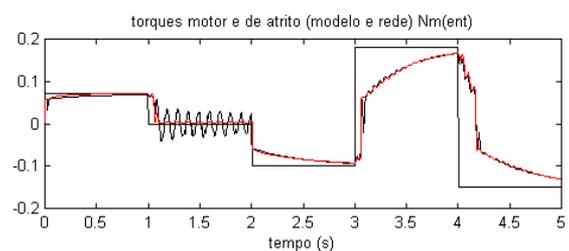


Figura 7. Torques, motor e de atrito (atrito identificado pela RNA em vermelho).

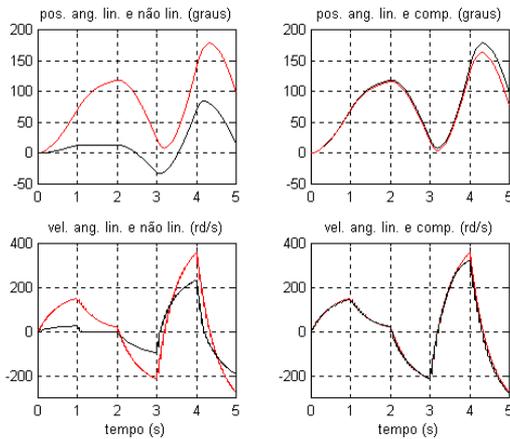


Figura 8. Posições e velocidades angulares (atrito linear em vermelho, torque motor em degraus).

Alguns resultados em malha fechada foram também obtidos. Utilizou-se um controle proporcional e derivativo (PD), nos casos com e sem o mecanismo de compensação. A Fig. 9 mostra o torque motor com a compensação de atrito, para degraus em posição em malha fechada, bem como os torques de atrito do modelo e da RNA. De forma semelhante aos casos em malha aberta, a identificação do atrito via RNA foi muito eficiente.

A Fig. 10 apresenta as respostas (posição e velocidade) do controle em malha fechada, para os casos do torque de atrito linear e não linear com e sem o mecanismo de compensação. No caso não linear sem a compensação, percebe-se que, para as pequenas amplitudes em degrau na entrada de referência, o torque motor de controle é menor do que o atrito estático, configurando-se assim o modo *stick*, não havendo portanto movimento. O caso não linear com a compensação de atrito se assemelha ao caso linear, mostrando desse modo a eficiência do mecanismo de identificação via RNA do atrito e da compensação deste a partir do mecanismo proposto.

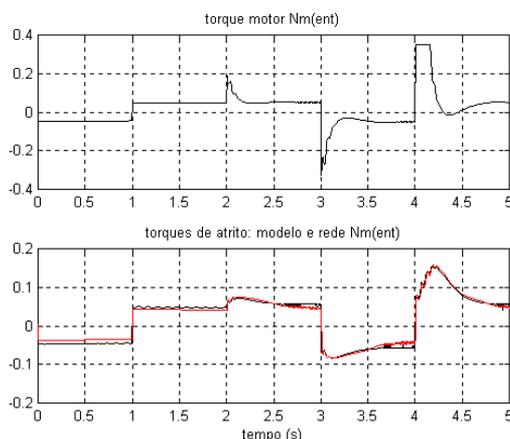


Figura 9. Torque motor com a compensação de atrito e torques de atrito (atrito da RNA em vermelho).

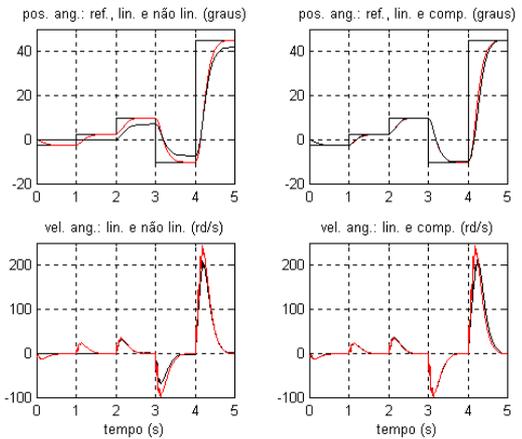


Figura 10. Posições e velocidades angulares em malha fechada (simulações com o atrito linear em vermelho).

6. Conclusões

Pode-se extrair, como principal conclusão deste trabalho, que uma RNA de configuração simples pode ser eficiente na identificação do torque de atrito não linear de um atuador robótico do tipo moto-reductor. O mecanismo proposto de compensação do atrito não linear, o qual utiliza a identificação (saída da RNA), mostrou-se muito eficiente. Como o modelo de atrito que serviu de base para formar os padrões de treinamento da RNA foi bastante testado experimentalmente, acredita-se que a estratégia de compensação de atrito proposta deva funcionar na prática para atuadores do tipo moto-redutores em geral, respeitando-se todas as etapas aqui desenvolvidas, inclusive a mesma estratégia de treinamento da RNA, a qual utilizou resultados em malhas aberta e fechada. Como continuação do presente trabalho, pretende-se adquirir um moto-reductor do tipo *harmonic-drive* a fim de se obter os resultados experimentais que comprovem em definitivo o que foi demonstrado em nível de simulação.

Referências

- [Armstrong, 1988] Armstrong, B. S. R. Dynamics for robot control: friction modeling and ensuring excitation during parameter identification. PhD thesis, Stanford University. 1988.
- [Beale and Jackson, 1990] Beale, R. and Jackson, T. Neural computing: an introduction. Adam Higler Bristol, 1990.
- [Dapper and Zanh, 1999] Dapper, M., Zanh, V., Maass, R. and Ekmiller, R. How to compensate stick-slip friction in neural velocity force control (NVFC) for industrial manipulators. In IEEE Robotic and Automation Conference, Detroit, USA, May, 1999.

- [Fausett, 1994] Fausett, L. Fundamentals of neural networks. Prentice Hall, New Jersey, 1994.
- [Gomes and Chrétien, 1992] Gomes, S. C. P. and Chrétien, J. P. Dynamic modeling and friction compensated control of a robot manipulator joint. In IEEE Robotic and Automation Conference, Nice, France, May, 1992.
- [Gomes, 1995] Gomes, S. C. P. Modelagem de atritos internos às articulações de robôs manipuladores. In XIII COBEM, CD-ROM, Belo Horizonte, 1995.
- [Jung, 1998] Jung, S. Hsia, T. C. Analysis of non linear neural network impedance force control for robot manipulator. In IEEE Robotic and Automation Conference, Leuven, Belgium, May, 1998.
- [Kaynak, 1997] Kaynak, O. and Ertugru, M. Neural network adaptive Sliding Mode Control and its application to SCARA type robot manipulator. In IEEE Robotic and Automation Conference, Albuquerque, New Mexico, USA, April 1997.
- [Miller, 1995] Miller III, W.T., Sutton, R.S., Werbos, P.J., Neural networks for control. MIT Press. 1995.
- [Selmic and Lewis, 2000] Selmic, R. R. and Lewis, F. L. Dead zone compensation in motion control systems using Neural Networks. IEEE Transactions on Automatic Control, Vol 45, April 2000.