

# Utilização do Controlador Neural por Linearização *Feedback* na Identificação e Controle da Velocidade de um Veículo Experimental

Ana Beatriz Alvarez Mamani, José Raimundo de Oliveira  
*Departamento de Engenharia de Computação e Automação Industrial (DCA)*  
*Faculdade de Engenharia Elétrica e Computação - UNICAMP*  
*Caixa Postal 6101 13083-852 Campinas, SP - BRASIL*  
[anabe@dca.fee.unicamp.br](mailto:anabe@dca.fee.unicamp.br), [jro@dca.fee.unicamp.br](mailto:jro@dca.fee.unicamp.br)

## Abstract

*This paper describe obtained results using the neural control by feedback linearization for the system identification and control of the speed of experimental car. It is known that the not controlled final speed of a experimental car is non linear due to some noise, obstacles or disturbances of the surface in which it moves. Thus, the objective of the use of the neural controller is to return the system of speed more robust to the parametric variations and mainly to compensate the non linear effects of the dependent gain of the margin of operation inherent of the speed systems. Here are discussed the experimental results that show a significant error reduction in steady-state and a uniformization of the permanent response of the closed-loop system.*

**Keywords:** *Neural Networks, System Identification, Control, Computer Modeling and Simulation, Speed.*

## 1. Introdução

As redes neurais têm sido aplicadas com muito sucesso na identificação [1,2] e no controle de sistemas dinâmicos [3,5], mesmo quando estes sistemas apresentam distúrbios desconhecidos, uma dinâmica complexa e possivelmente desconhecida, efeitos não-lineares, e também uma dinâmica múltipla com escalas de tempo diferentes. Como exemplo destes sistemas temos: sistemas de posicionamento, sistemas robóticos de velocidade elevada, sistemas auto-guiados, sistemas militares e assim por diante; todos estes incluem sistemas físicos que em geral são lineares apenas em pequenos intervalos de operação apresentando algumas não linearidades que limitam o desempenho dos mecanismos fazendo com que os mesmos não operem adequadamente.

Dentre os efeitos não lineares mais comuns temos os seguintes: *zona morta*, pequeno intervalo no qual o sistema mesmo recebendo excitação não responde, *ganho dependente da faixa de operação*, conhecido também como ganho não linear, onde o ganho do sistema não é representado por uma constante e *saturação*, na qual a saída do sistema satura para grandes sinais da entrada.

As exigências de desempenho modernas nos termos da velocidade e na precisão do movimento para sistemas de condução automática de veículos (auto-guiados) são muito estritas. Tudo isto faz o projeto de sistemas de controle extremamente complicado e difícil. Tomemos em consideração que para um sistema de velocidade com uma porcentagem de alta fidelidade, um erro aceitável na saída é de 2% do seu valor referencial como máximo [11]

O controle de sistemas não-lineares é um assunto que desperta grande interesse dos pesquisadores. Técnicas de controle clássica são baseadas em modelos linearizados dos sistemas físicos, o que representa perda de informações, que muitas vezes são importantes para o funcionamento do sistema com altos níveis de exigência. Atualmente, a utilização de diferentes técnicas de controle inteligente tem aberto uma nova perspectiva no tratamento de sistemas não-lineares e no projeto de seus controladores. As referências [6,7] mostram excelentes resultados utilizando as redes neurais no processo de identificação de não linearidades para controle.

Este artigo mostra o desempenho do controlador neural por linearização *feedback* na identificação e controle da velocidade de um veículo experimental cuja velocidade não controlada carrega características não lineares (ganho não linear) devido a vários ruídos, obstáculos ou perturbações da superfície na qual se movimenta. O esquema de identificação e controle utilizado tem como unidade básica o perceptron de

múltiplas camadas (MLP), este esquema foi desenvolvido por Narendra [3,4] mostrando-se muito eficaz em sistemas dinâmicos não lineares.

## 2. O sistema de velocidade

Geralmente a arquitetura de um sistema de controle de velocidade inclui vários módulos como: planta a ser controlada, sensores, módulos de acondicionamento do sinal, de acondicionamento de potência, entre outros.

Neste estudo a denominada planta é um veículo experimental que funciona com um motor CC controlado por armadura alimentado por uma bateria de 7V. A velocidade de saída é função das características do ambiente no qual o veículo se movimenta, tendo como exemplo os seguintes casos:

- Chão não uniforme, existe um parâmetro de atrito consideravelmente alto, neste caso a velocidade com que se movimenta não seguirá a velocidade referencial haverá uma perturbação.
- Devido a alguns obstáculos no ambiente o veículo não percorre livremente, tendo a velocidade de saída do motor constante e a velocidade final do veículo inconstante.
- Quando o chão está muito liso e a velocidade aumentar rapidamente. Neste caso, a velocidade na saída do motor estará dando um valor de velocidade correta, mas a velocidade de saída pode estar acima da referencial.

Para a simulação destes casos, quando a velocidade varia em função ao ambiente, utilizamos uma perturbação de amplitude ( $T_c$ ) igual ao 10% da sinal de entrada, caracterizados como segue:

- Um passo positivo da perturbação indica que a velocidade do veículo diminuiu, por atrito no chão, obstáculos ou outro motivo, este passo faz com que a corrente de armadura aumente de maneira que a velocidade de movimentação siga sua referencial.
- Similarmente acontece no caso quando a velocidade do veículo aumenta, um passo negativo de perturbação faz com que a corrente de armadura se ajuste para manter o veículo a uma velocidade referencial.

Para os primeiros testes a planta é constituída pelo motor CC configurado por armadura que tem como entradas a voltagem da bateria e a perturbação de amplitude ( $T_c$ ).

## 3. Redes neurais artificiais para controle

As redes neurais podem ser de grande utilidade em processos industriais e/ou sistemas dinâmicos porque provaram ter potencialidades excelentes na

aproximação de funções, uma vez que muitos processos são altamente não lineares. Um dos tipos mais comuns de redes neurais *feedforward* é o perceptron de múltiplas camadas (MLP), este tipo de rede já foi referenciado não somente para modelagem de vários processos biológicos e industriais como, também para projetar controladores para eles com benefícios significativos.

Tipicamente existem dois passos envolvidos quando usamos redes neurais para controle: a identificação do sistema e o projeto de controle. No sistema de identificação é desenvolvido um modelo de rede neural da planta que será controlada, e no projeto de controle, o modelo neural da planta é usado para treinar o controlador.

Há uma variedade de controladores de sistemas nas quais as redes de múltiplas camadas podem ser usadas como blocos de construção básica [8,9], sendo três os esquemas mais populares: controle neural preditivo, controle neural por linearização *feedback* e controle neural baseado em modelo de referência. Estes controladores são representantes da variedade de maneiras em que as redes de múltiplas camadas são usadas em sistemas de controle. Como na maioria de controladores neurais, eles são baseados em arquiteturas padrão de controle linear.

## 4. Controle neural por linearização *feedback*

Uma implementação da técnica de linearização *feedback* é mostrada na figura 4.1. Ela produz um sinal de controle com dois componentes, o primeiro cancela as não linearidades na planta, e o segundo é um controlador linear de estado *feedback*.

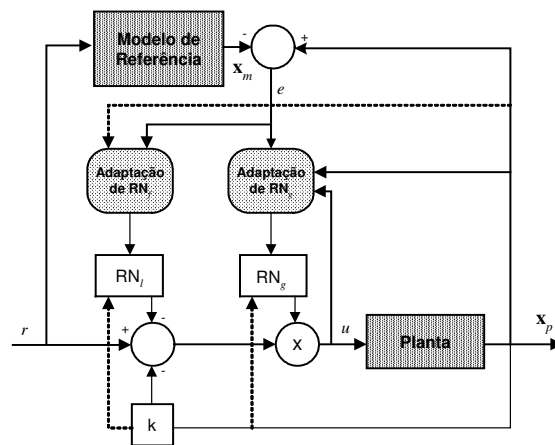


Figura 4.1. Linearização *feedback* neural

Esta técnica pode ser aplicada aos sistemas não lineares cujo modelo da planta pode ser expressado pela forma canônica descrita pela equação 4.1 [10].

$$\dot{\mathbf{x}}_p^{(n)} = l(\mathbf{x}_p) + g(\mathbf{x}_p)u \quad 4.1$$

$\mathbf{x}_p = [x_p \dot{x}_p \dots x_p^{(n-1)}]^T$  contém o sistema de variáveis de estado e  $u$  é a entrada de controle.

Há algumas variações do controlador neural adaptativo que utilizam linearização *feedback*, incluindo os modelos aproximados de Narendra. O modelo utilizado neste trabalho é um dos mais conhecidos é referido por Narendra como controle NARMA-L2, descrito a seguir.

#### 4.1. Identificação do modelo NARMA-L2

O primeiro passo para usar linearização *feedback* é identificar o sistema a ser controlado. O modelo NARMA-L2 é uma aproximação do modelo NARMA (Eq. 4.2).

$$y(k+d) = N[y(k), y(k-1), \dots, y(k-n+1), u(k), u(k-1), \dots, u(k-m+1)] \quad 4.2$$

$u(k)$  é a entrada ao sistema, e  $y(k)$  a saída do sistema.

No procedimento de identificação uma entrada de controle é resolvida para que faça a saída do sistema seguir alguma trajetória de referência.

$$y(k+d) = y_r(k+d) \quad 4.3$$

Assim, o sinal de controle não linear desenvolvido teria a forma:

$$u(k) = G[y(k), y(k-1), \dots, y(k-n+1), y_r(k+d), u(k-1), \dots, u(k-m+1)] \quad 4.4$$

Utilizando este sinal de controle, deveria ser treinada uma rede neural dinamicamente para produzir a função  $G$  de tal maneira que o erro quadrático médio seja mínimo.

Narendra e Mukhopadhyay [4] propõem o uso de um modelo aproximado para representar o sistema. O modelo aproximado é chamado NARMA-L2 (Eq. 4.5).

$$\hat{y}(k+d) = l[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-m+1)] + g[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-m+1)] \cdot u(k) \quad 4.5$$

Este modelo está na forma canônica (Eq. 4.1), onde a seguinte entrada de controle  $u(k)$  não está dentro da não linearidade e tem a forma:

$$u(k) = \frac{y_r(k+d) - l[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-n+1)]}{g[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-n+1)]} \quad 4.6$$

Para não ter problemas de realização devido ao sinal de controle  $u(k)$  baseado na saída ao mesmo tempo, usam o modelo da equação 5.7 ( $d \geq 2$ ).

$$y(k+d) = l[y(k), y(k-1), \dots, y(k-n+1), u(k), u(k-1), \dots, u(k-n+1)] + g[y(k), \dots, y(k-n+1), u(k), \dots, u(k-n+1)] \cdot u(k+1) \quad 4.7$$

#### 4.2. Controle NARMA-L2

Utilizando o modelo NARMA-L2, o controlador obtido é expressado pela equação 4.8 (realizável para  $d \geq 2$ )

$$u(k+1) = \frac{y_r(k+d) - l[y(k), y(k-1), \dots, y(k-n+1), u(k), \dots, u(k-n+1)]}{g[y(k), y(k-1), \dots, y(k-n+1), u(k), \dots, u(k-n+1)]} \quad 4.8$$

Este controlador pode ser implementado com o modelo da planta previamente identificado NARMA-L2, como mostra a figura 4.2.

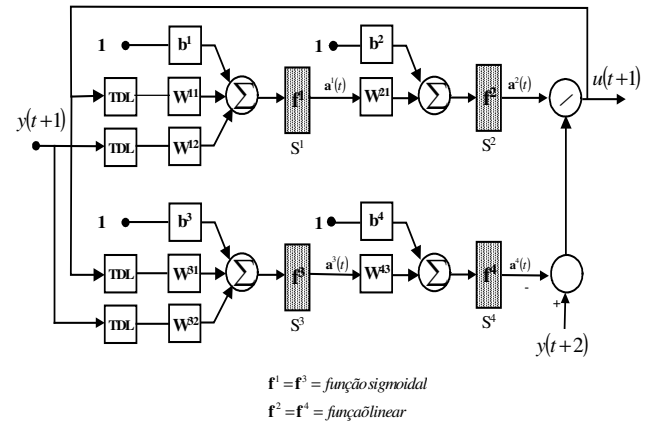


Figura 4.2. Controlador neural por linearização *feedback*

### 5. Parte experimental

Para a simulação foram utilizadas diferentes bibliotecas do Simulink/Matlab, os parâmetros utilizados serão detalhados ao longo da simulação.

Neste item são detalhados dois casos. O primeiro utiliza como referência um sinal tipo degrau e o segundo utiliza um sinal tipo trem de pulsos ascendente, cujo propósito é verificar o controle de efeitos não lineares na resposta final do sistema. Todos os resultados da simulação são variáveis impressas em função do tempo.

Foram consideradas 5000 amostras de treinamento, como critério de parada: o número de épocas alcançado ou erro mínimo atingido. O conjunto de amostras foi dividido em dados de treinamento, validação e teste. A quantidade máxima de iterações ou épocas permitidas é fixa em 1000.

### 5.1. Caso 1

O ruído de perturbação  $T_c$  é 10% da magnitude da entrada e considerado na fase de treinamento para dar robustez à rede, se admite condições iniciais nulas e como referência um sinal tipo degrau. Nas tabelas 5.1 e 5.2, está especificado a arquitetura final da rede, e o resultado de treinamento, respectivamente.

Tabela 5.1. Arquitetura da rede

Tamanho da camada intermediária	3
Intervalo de amostragem das entradas (seg.)	0.01
No. de entradas retardadas da planta	3
No. de saídas retardadas da planta	3

Tabela 5.2. Resultado de treinamento

Parada	No. Máximo épocas (1000)
MSE de treinamento	1.55402e-009
MSE de validação	1.18343e-009
MSE de teste	5.48249e-010

Na figura 5.1 se detalham as duas saídas, uma controlada e a outra não, pode-se perceber que a ação do controlador em regime permanente (Fig. 5.2) faz com que o valor de saída acompanhe o valor referencial de forma eficiente, o erro (Fig. 5.3) mantém-se próximo de zero, mudando ligeiramente apenas quando há variação no valor da perturbação  $T_c$ . Devido ao controle, o efeito das variações de carga foi minimizado e não alteram a velocidades do motor, uma vez que as variações não ultrapassam de 2%.

### 5.2. Caso 2

A característica principal deste caso é a modificação do sinal de entrada, utiliza-se como referência de velocidade um sinal tipo trem de pulsos ascendente, os




Figura 5.1. Velocidade de saída real e saída controlada




Figura 5.2. Ação do controlador




Figura 5.3. Detalhe para o erro da velocidade

parâmetros que caracterizam a identificação e controle do sistema são os mesmos descritos no primeiro caso.

Identificada a planta e implementado o controlador neural. As figuras 5.5 e 5.6 apresentam o resultado da simulação: a velocidade referencial e velocidade de saída da planta e a ação de controle, respectivamente. Dos resultados podemos dizer que a sinal de controle consegue compensar as não linearidades presentes no sistema sem controle (figura 5.4).

Como parte complementar do primeiro caso, foram implementados outros dois controladores neurais: controle neural preditivo e controle neural baseado em modelo de referência.

Os parâmetros de treinamento e a arquitetura da rede no processo de identificação foram mantidos constantes para o teste dos três controladores. Entretanto foi necessário aumentar o tamanho da rede no processo de identificação utilizando o controlador neural baseado em modelo de referência. Isto porque, mantendo o mesmo tamanho dos outros dois testes, não conseguimos uma boa identificação das não linearidades do sistema num tempo razoável.

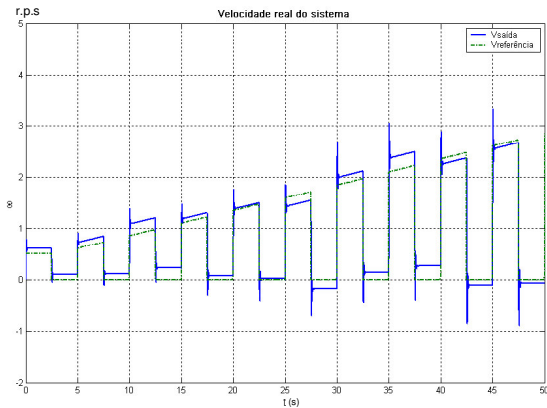


Figura 5.4. Resposta do sistema sem controle: ganho não linear

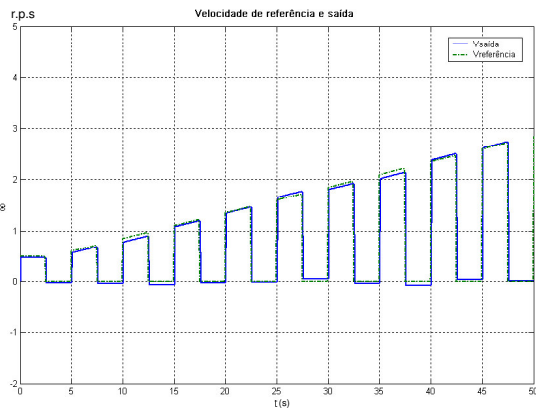


Figura 5.5. Comportamento da velocidade com compensação do ganho não linear




Figura 5.6. Ação do controlador

No primeiro caso de estudo, os três esquemas de identificação desenvolvidos pelos três controladores mostram-se muito eficazes ao identificar as não linearidades presentes no sistema. Observando que no projeto do controle o controlador que gastou menos tempo para obter bons resultados foi o “Controlador por Linearização Feedback”.

Com esta comparação não desmerecemos as qualidades dos outros dois controladores. Assim, podemos dizer que cada estrutura de controle tem seu

campo de aplicação, que varia em função do requerimento de controle da planta e em função das características da planta a controlar.

## 6. Conclusões e trabalhos futuros

Neste artigo foram apresentados resultados obtidos utilizando o controlador neural por linearização *feedback* para o controle da velocidade. Podemos dizer que para o controle de velocidade objeto deste nosso estudo foram consideradas como características primordiais do controlador: o tempo de aprendizado, o tempo de resposta e o menor tamanho da rede, viabilizando a sua implementação futura utilizando um microcontrolador como unidade central de processamento.

Assim, a análise dos resultados utilizando o Controlador Neural por Linearização *Feedback* mostra que as respostas obtidas são aceitáveis e prometedoras para o objetivo do controle.

Novos desafios no desenvolvimento do módulo controlador contemplam:

- Implementação do controle de velocidade em hardware.
- Incorporação de outros recursos para o controle autônomo do veículo.

## 7. Referências

- [1] Chen, S. and Billings, S., "Neural networks for non-linear dynamic system modelling and identification," *Int. J. Control*, Special Issue on Intelligent Control, 1992, Vol.56, No.2, pp.319-346.
- [2] Sjöberg, J., et al., "Non-linear black-box modeling in system identification: a unified overview", *Automática*, 1995, Vol 31, pp. 1691-1724,.
- [3] Narendra, K.S. and K. Parthasarathy, "Identification and Control of Dynamical Systems Using Neural Networks," *IEEE Transactions on Neural Networks*, 1990, vol. 1, pp. 4-27.
- [4] Narendra, K.S. and S. Mukhopadhyay, "Adaptive Control Using Neural Networks and Approximate Models," *IEEE Transactions on Neural Networks*, 1997, vol. 8, pp. 475-485.
- [5] Hunt, K.J., D. Sbarbaro, R. Zbikowski and P.J. Gawthrop, "Neural Networks for Control System - A Survey," *Automática*, 1992, vol. 28, pp. 1083-1112.
- [6] Bauchspiess, A.; Drummond, A.C.; Romariz, A.R.S.: "Servocontrole Não-Linear Auto-Sintonizado por Redes Neurais de Base Radial," *3 SBAI - Simpósio Brasileiro de Automação Inteligente*, Vitoria/ES-BRAZIL, Sep. 1997, pp. 430-435.

[7] Pedrosa, Z.; Bauchspiess, A., "Implementação do Servocontrole Auto-Sintonizado em Tempo-Real Utilizando Rede Perceptron Multicamadas", *Proceedings of IV Brazilian Conference on Neural Networks*, ITA, São José dos Campos - SP - Brazil, Jul. 20-22 1999, pp. 888-999.

[8] Hagan, M. T. and H.B. Demuth, "Neural Networks for Control," *Proceedings of the 1999 American Control Conference*, San Diego, CA, 1999, pp. 1642-1656.

[9] G. Bloch and T. Denoeux. "Neural networks for process control and optimization: two industrial applications", *ISA Transactions*, 42(1), 2003, pp. 39-51.

[10] A.J.N. Van Breemen and L.P.J. Veelenturf, "Neural Adaptive Feedback Linearization Control," *Journal A*, vol. 37, 1996, pp. 65-71.

[11] A.E., Fitzgerald and Jr. Kingsley, *Máquinas elétricas: Conversão eletromecânica de energia, Processos dispositivos e sistemas*, cap. 9.