

# Servocontrole não linear Auto-Sintonizado por Redes Neurais de Base Radial

Adolfo Bauchspiess<sup>1</sup>  
Adriana de C. Drummond<sup>1</sup>  
Alexandre R. S. Romariz<sup>1</sup>

<sup>1</sup>GRACO – Grupo de Automação e Controle, <http://www.graco.unb.br>  
Departamento de Engenharia Elétrica - Universidade de Brasília – UnB  
70910-900 – Brasília / DF – BRASIL  
bauchspiess@ene.unb.br, adriana@ene.unb.br, romariz@ene.unb.br

**Abstract:** This paper discusses the use of Radial Basis Function (RBF) Neural Networks for the identification and control of positioning systems. The point in using neural networks is to give the system greater robustness against parameter variations, measuring noise and specially to compensate the most commonly encountered non linear effects on this kind of systems: dead zone, saturation and non-linear gain. For the experimental part a DC servomotor with tacometric and position feedback is used. The network is used in a closed loop scheme adjusting the parameters of non-linear classical controllers. A digital PID controller implemented on a Transputer is used to establish the resulting linear dynamics. First experimental results are discussed, pointing out a significant steady-state error reduction and a uniformization of the transitory response of the closed-loop system.

**Keywords:** Non-linear control, neural networks, DC motor servo-positioning.

**Resumo:** Este artigo discute a aplicação de Redes Neurais de Base Radial para a identificação e o controle de sistemas posicionadores, objetivando tornar o sistema mais robusto a variações paramétricas, a ruídos de medida e principalmente compensar os efeitos não lineares mais comuns encontrados neste tipo de sistema: zona morta, saturação e ganho não linear. Na parte experimental é empregado um servoposicionador baseado num motor de corrente contínua com realimentação tacométrica e de posição. A rede é empregada em malha fechada para o ajuste dos parâmetros do controlador não-linear clássico. Um controlador PID digital foi implementado em um Transputer para estabelecer a dinâmica do sistema linear resultante. São discutidos primeiros resultados experimentais, que mostram uma significativa redução do erro em regime e uma uniformização da resposta transitória do sistema em malha fechada.

**Palavras-Chave:** Controle não-linear, redes neurais, servoposicionador com motor CC.

## 1. Introdução

Sistemas de controle de posição baseados em motores CC são utilizados com esquemas de controle clássico há muito tempo. O esquema de controle mais utilizado consiste numa malha de realimentação analógica de corrente, de resposta rápida, e uma cascata de realimentações de posição e tacométrica. Neste caso, o controle linear mais difundido é o controle Proporcional - Integral (PI). Para que seja possível projetar um controlador deste tipo é necessário um modelo linearizado da planta original, que portanto, não considera efeitos não-lineares normalmente presentes neste tipo de sistema, como

zona morta, saturação e ganho dependente do ponto de operação.

Estas não-linearidades podem ser calculadas analiticamente utilizando algumas variáveis características obtidas da resposta do sistema em malha aberta, como o erro de regime e o valor máximo de saída. A obtenção destes parâmetros em tempo real, no entanto, está sujeita a vários tipos de ruído e imprecisões de medida.

Neste artigo é discutida a utilização de redes neurais para tornar mais robusto este processo de extração de parâmetros [9]. Uma Rede de Base Radial será usada para identificar as não-linearidades atuando sobre a planta (amplitude do ganho e da zona morta) a partir de medidas da resposta do sistema em

malha aberta (erro em relação ao sistema linearizado, amplitude máxima de saída, amplitude de referência). A idéia é empregar a rede para a adaptação de parâmetros de um controlador clássico que compensa as não-linearidades da planta.

## 2. O Sistema servoposicionador

O sistema servoposicionador utilizado neste trabalho foi o pertencente ao 'kit' da marca Feedback®, modelo MS-150. Este 'kit' consta de um motor de corrente contínua, um servo-amplificador, um atenuador, um pré-amplificador, dois potenciômetros (um de entrada e um de saída) e uma fonte [5], como pode ser visto esquematicamente na Figura 1:

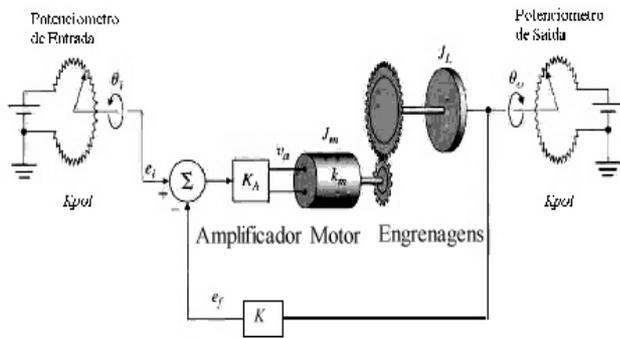


Figura 1 - Esquema do sistema servoposicionador.

onde:

$$e_i = K_{pot} \theta_i, \quad e_o = K_{pot} \theta_o,$$

$$K_{pot} = [V/rad],$$

$$T = \text{torque do motor} = k_m i_a,$$

$$k_m = \text{constante de torque} = [N.m / A],$$

$$R_a = \text{resistência de armadura} = [\Omega],$$

$$L_a = \text{indutância de armadura} = [H],$$

$$\text{Tensão contra-eletromotriz} = k_e \dot{\theta}_o, k_e = [V.s / rad],$$

$$\text{Razão de engrenagem} = 1:n,$$

$$J_L + J_m = \text{momento de inércia total} = [kg.m^2],$$

$$B = \text{Coeficiente de atrito viscoso} [\mu F],$$

$$\text{Sinal gerado pelo atuador: } v_a = K_A (e_i - e_o).$$

A representação em diagrama de blocos deste sistema servoposicionador é mostrada na Figura 2.

A função de transferência linearizada deste servoposicionador, para um certo ponto de trabalho, em malha aberta, pode ser descrita por:

$$G(s)H(s) = \frac{K_A}{s(\tau_1 s + 1)(\tau_2 s + 1)} \quad (1)$$

Onde  $K_A$  é o ganho em CC,  $\tau_1 = (J_L + J_m)/B$  é a constante de tempo mecânica e  $\tau_2 = L_a/R_a$  é a constante de tempo elétrica do sistema. O polo na origem indica o

controle de posição. Para o controle de velocidade simplesmente suprime-se o polo na origem.

Estes sistemas são assim, fundamentalmente constituídos por um motor c.c. e por um servo-amplificador que pode ser configurado por armadura ou por campo. Neste caso a configuração escolhida foi de armadura, por apresentar um funcionamento mais estável.

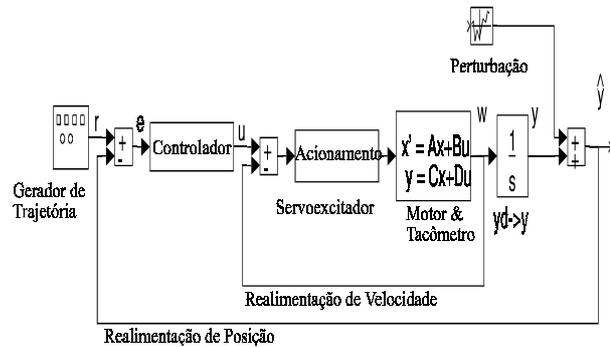


Figura 2 - Diagrama de blocos do servocontrolador.

O controle desta planta pode ser feito através da velocidade do eixo do motor ou da posição angular do potenciômetro de saída. Para as primeiras implementações foi escolhido o controle de velocidade (estável em malha aberta). Esta velocidade será analisada sob a forma de tensão, que será medida entre os terminais do tacômetro. O tacômetro é um dispositivo (gerador) que produz uma tensão proporcional à sua velocidade de rotação.

Como qualquer sistema físico real, o sistema de posição degrada com o envelhecimento de componentes e devido a suas não-linearidades inerentes. O controlador, baseado em redes neurais artificiais, deverá amenizar o efeito desses fenômenos no desempenho do sistema em malha fechada.

## 3. As redes neurais de base radial

Redes RBF (Radial Basis Function) têm dupla origem histórica: como sistema neural de inspiração biológica e aprendizado rápido e como método de aproximação de funções. Do ponto de vista de inspiração biológica, baseia-se no modelo de campos sobrepostos de recepção, presentes em regiões do córtex cerebral ligadas a processamento de informações sensoriais. O caráter de atividade local de seus processadores traz vantagens em rapidez de aprendizado [9]. De maneira independente, vários estudos indicaram a boa capacidade de aproximação em sistemas com funções de base radiais [10]. A Figura abaixo representa uma RBF:

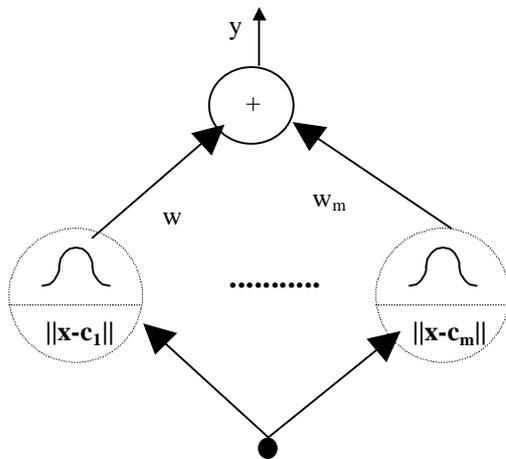


Figura 3: Representação de rede RBF

A entrada é apresentada a um conjunto de neurônios com função de ativação radialmente simétrica. Pode-se usar, por exemplo, uma gaussiana do tipo

$$y_i = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{c}_i\|^2}{\sigma_i^2}\right) \quad (2)$$

onde a norma  $\|\cdot\|$  costuma ser uma simples distância euclidiana. A saída desta camada inicial é então usada em uma soma ponderada que representa a saída final da rede. Existem para esta rede resultados de aproximação universal, semelhantes aos existentes para a rede Perceptron multicamada.

O principal interesse neste tipo de rede na área de sistemas conexionistas está no caráter local do processamento dos neurônios constituintes. Cada ponto de entrada excita principalmente um pequeno subconjunto dos neurônios da primeira camada. Sendo assim, durante o treinamento, pontos distantes da área de atuação de uma unidade não influenciam o ajuste de seus parâmetros. Este caráter local do treinamento faz com que novos aspectos do problema possam ser aprendidos sem prejuízo do que já se conhece, característica dificilmente obtida no Perceptron multicamada. Sendo assim, esta rede presta-se melhor, a princípio, para adaptação *on-line*.

Como vantagem adicional, durante a operação da rede (após treinamento), uma saída de baixo valor em todos os neurônios indica uma “novidade” em relação aos exemplos usados para aprendizado, o que serve de alerta no caso de operação do sistema em condições radicalmente diferentes das previstas.

Ainda outro foco de interesse é a equivalência funcional entre estes sistemas e um conjunto de regras nebulosas, cujo conseqüente estaria representado pelos valores numéricos dos pesos  $w_i$  [15].

É mais comum o uso de redes neurais quando temos um mapeamento complexo e não-linear, para o qual não se conhece um modelo preciso, mas apenas exemplos entrada x saída. Quando existem métodos analíticos para determinação da relação entre variáveis, o uso de rede neural pode ainda ser uma alternativa interessante considerando-se redundância e tolerância a ruído. O método analítico geralmente apresenta alta sensibilidade à precisão dos dados de entrada, uma Rede Neural, por outro lado, se treinada em condições representativas da operação real do costuma exibir boa robustez a erros na aquisição de parâmetros [12].

Há várias alternativas para o treinamento da rede. Em geral, não se opta pela otimização dos parâmetros  $\mathbf{W}$ ,  $\mathbf{c}$  e  $\sigma$  ao mesmo tempo partindo-se de valores aleatórios, já que problemas de condicionamento numérico podem ocorrer se para vários pontos do treinamento nenhum neurônio de entrada responde adequadamente de início. Uma melhor alternativa é definir a princípio um conjunto fixo de centros e variâncias para as funções de base.

Nesta fase, durante o presente trabalho, foram identificados problemas quando se optou por fixar o centro dos neurônios radiais com base na distribuição dos pontos de entrada. Em dados do mundo real, estes pontos podem não ser uniformemente distribuídos, caso em que este tipo de treinamento pode apresentar instabilidade ou resultar em uma rede com número excessivo de processadores.

Uma solução mais simples e que apresentou melhores resultados foi a simples distribuição uniforme de processadores sobre o espaço de entrada. Outras soluções possível é um algoritmo de mapeamento auto-organizável. Conhecimento prévio sobre o problema pode também ser útil nesta etapa, diferentemente do que ocorre no treinamento de um Perceptron Multicamada [16].

Fixados os parâmetros dos processadores gaussianos, o problema de otimização é linear e sobre-determinado, para o qual adota-se uma solução de norma mínima. Se necessário, todos os parâmetros da rede podem passar conjuntamente por um processo de ajuste fino, utilizando por exemplo o gradiente do erro de saída, visando uma melhor capacidade de generalização.

#### 4. Controle não linear

Esquemas de controle em malha fechada clássicos para o motor estão esquematizados na Figura 4. O controlador recebe a referência e o sinal de medida da variável controlada  $\hat{y}$  e produz o sinal de atuação  $u$ .

Este esquema de controle é utilizado em diversas abordagens encontradas na literatura, onde o bloco “controlador” é substituído por uma rede neural [15].

Neste trabalho, em vez de utilizar uma rede neural diretamente como controlador, a proposta é utilizar uma rede neural para fazer o ajuste paramétrico, num esquema de compensação não-linear “feed-forward” (utilizando o funcional inverso) de estrutura conhecida, Figura 4 . Isto está ilustrado, a título de exemplo, para o caso da compensação da zona morta e de um ganho não-linear sigmoidal simétrico utilizando um compensador que implementa a característica recíproca (atrito coulombiano e inversa da sigmoide simétrica),

Utilizando-se a mesma idéia podem ser compensados diversos tipos de não-linearidades. A idéia básica é: “não pedir da rede o que é conhecido analiticamente”. A estrutura do controlador não-linear é conhecida; a rede neural deve “apenas” fazer (eventualmente diversas vezes durante a vida útil do sistema) o ajuste fino dos seus parâmetros.

Da seqüência de degraus com amplitudes crescentes pode ser utilizado um pré-processamento analítico, visando reduzir a dimensão do vetor de entrada, que extrai para cada degrau as seguintes informações:

- $e$  – erro em regime
- $r$  – amplitude do sinal de referência
- $y_{max}$  – máximo atingido na resposta

Esta abordagem permite também que os elementos do vetor de treinamento sejam livremente permutados (o que é normalmente recomendado para o treinamento de redes neurais). Isto não seria possível se utilizássemos como vetor de entradas um sinal no tempo.

Além desse primeiro pré-processamento, para melhorar o desempenho da rede neural é possível também utilizar valores de pequenos sinais para cada um destes parâmetros, i.e., a diferença dos parâmetros medidos menos os da planta linear de referência.

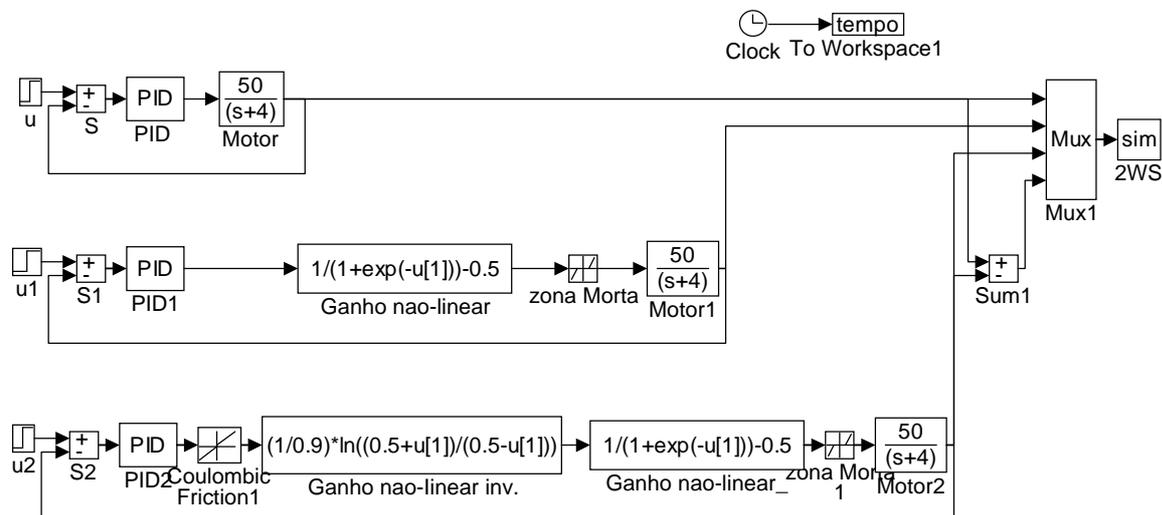


Figura 4 – Diagrama de Simulação (SIMULINK®-MATLAB®)

- Sistema linearizado – Modelo de Referência.
- Sistema Posicionador não-linear
- Sistema não-linear com Controlador não-linear sintonizado pela RBFN

A tarefa da rede neural é retirar dos sinais pré-processados, conforme descrito acima, os valores:  $Z_m$  – a zona morta, e  $K$  - ganho no ponto atual de operação. A rede neural deve ser treinada com sinais de treinamento ricos o suficientes para permitir identificar o mapeamento não-linear subjacente. Ruído deve ser considerado na fase de treinamento para dar robustez à rede. Obtendo-se estes parâmetros característicos das não-linearidades basta fazer o ajuste do compensador não-linear. Este ajuste não deve ser feito arbitrariamente, pois como nos controladores adaptativos, é inserida uma dinâmica adicional ao sistema pelo processo de ajuste de parâmetros, o

que eventualmente pode levar à instabilidade do processo [11]. Em situações normais um ajuste de parâmetros a uma taxa de amostragem muito mais baixa que as constantes de tempo do sistema em questão não traz dificuldades. Ajustes em intervalos de tempo maiores (p.ex. ao ligar-se uma máquina, no procedimento de auto-teste) levam a sistemas auto-ajustáveis.

Uma vez que o compensador “feed-forward” linearizou o processo técnicas de controle clássico, como o controlador PI, ou PID podem ser utilizadas para estabelecer a dinâmica de malha fechada para acompanhamento de sinais e de rejeição de perturbações. A figura 5 mostra o diagrama de blocos do sistema posicionador com o controle auto-sintonizável.

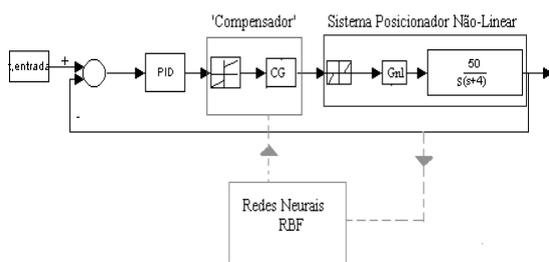


Figura 5 – Esquema de compensação não-linear ajustado por rede neural.

Este esquema de controle pode facilmente ser implementado em microcontroladores digitais, onde uma função de auto-ajuste pode ser programada para ser executada ao colocar-se o sistema em operação e com uma certa periodicidade para compensar variações de componentes devido a envelhecimento.

Para a formação da matriz de treinamento da rede foi necessário um pré-processamento do sinal de saída do sistema, para que fossem retirados os parâmetros utilizados no treinamento (erro em regime e amplitude máxima alcançada). Este processamento foi realizado através de uma rotina escrita no ambiente MATLAB.

## 5. Aparato Experimental

Para a verificação dos resultados teóricos foi utilizado um motor servoposicionador de corrente contínua MS150 da Feedback, Figura 6.

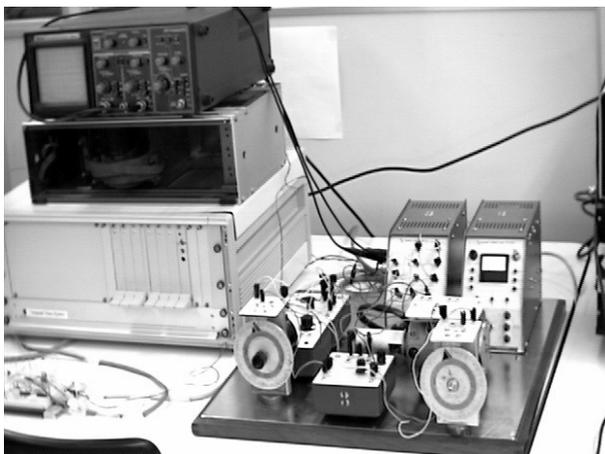


Figura 6 – Servoposicionador MS150-Feedback Transputer System - Parsytic.

Um sistema de processamento paralelo da Parsytec baseado em Transputers T805 foi utilizado para a implementação digital do esquema de controle proposto. O Transputer está acomodado no gabinete à esquerda, A/D e D/A sob o osciloscópio e o servo MS-150 pode ser visto à direita nesta figura.

Para a excitação e a aquisição da resposta do sistema posicionador foram utilizadas placas de interfaceamento A/D e D/A conectadas ao Transputer. Este por sua vez comunicava com um PC-Pentium (Host) para estabelecer a interface com o usuário. O programa de controle do motor CC foi desenvolvido em linguagem C-Concorrente [14]. Este programa é ativado de dentro do ambiente MATLAB, que foi aqui utilizado para a visualização dos resultados.

## 6. Resultados

Foram obtidos resultados com dois conjuntos de simulações. No primeiro, foi utilizado o SIMULINK para implementar a estratégia de controle proposta na Figura 4. Na Figura 7 vemos que o compensador teve desempenho adequado, mesmo com um pequeno erro de identificação nos parâmetros fornecidos como resposta da rede (arbitrado em 10%).

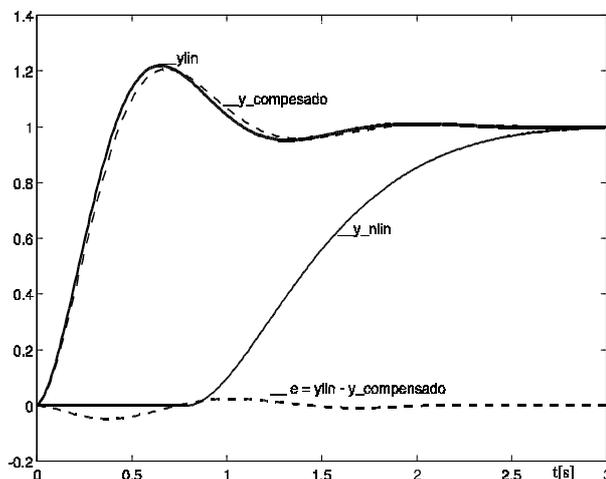


Figura 7 – Simulação da resposta do sistema com e sem compensador não-linear (SIMULINK).

Em seguida, a rede RBF foi treinada, utilizando-se para isto um conjunto de dados obtidos do sistema físico para as variáveis de entrada da rede, conforme definidas na seção anterior. Neste estágio pretendia-se avaliar a capacidade de representação da rede para o mapeamento-objetivo. As Figuras 8 apresentam resultados do desempenho da rede (erro em relação aos valores desejados) para pontos do arquivo de teste, ou seja, pontos diferentes dos apresentados no treinamento. Os resultados sugerem boas perspectivas para a operação do sistema com dados reais de operação, o que foi confirmado mais tarde nos testes de laboratório.

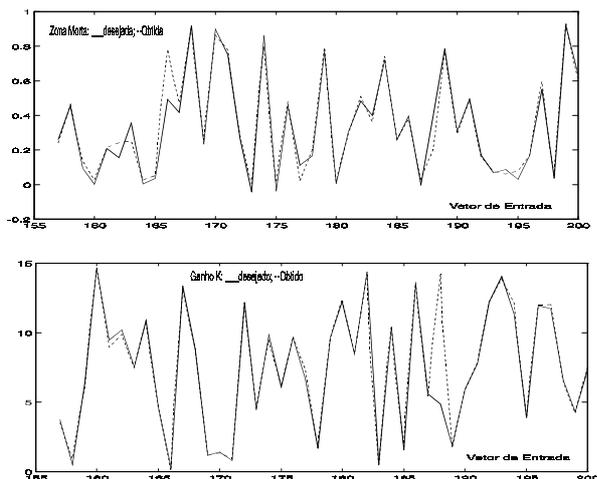


Figura 8 – Resultados obtidos da identificação de parâmetros com RBFN.

A figura 9 mostra resultados obtidos para o controle do servo-posicionador MS150 com o esquema de controle proposto. Nota-se que a compensação da Zona Morta (ZM) e do Ganho Não-Linear (GNL) reduz bastante o erro em regime e torna a resposta transitória mais uniforme. O atrito, uma não-linearidade não-determinística, mostrou ser a principal dificuldade para se obter um posicionamento preciso do motor.

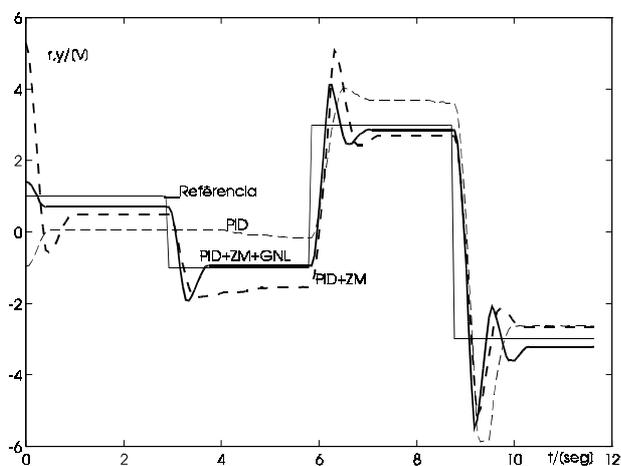


Figura 9 – Resposta obtida com e sem compensador não-linear auto-sintonizado por Rede Neural para o servoposicionador MS150.

## 7. Conclusões e Perspectivas

Neste artigo, uma proposta de controlador não-linear baseado em redes neurais de base radial foi apresentada. A rede identifica os parâmetros não-lineares do sistema, fornecendo-os a um compensador não-linear clássico, que virtualmente cancela os principais efeitos não lineares. Um controlador PID estabelece a dinâmica do sistema resultante.

Os resultados obtidos para o esquema de controle proposto, tanto em simulação como em

testes de laboratório mostraram excelentes resultados.

Um efeito não linear importante, que está sempre presente em sistemas físicos reais, a saturação, não foi considerada neste trabalho. Numa continuação deste trabalho serão utilizadas técnicas de controle avançadas (estrutura variável com transição suave [16]), que permitem aumentar significativamente a faixa de operação dinâmica de sistemas posicionadores na presença de saturações.

*Os autores agradecem ao CNPq pelo apoio a este projeto na forma de uma bolsa PIBIC e ao GRACO pela disponibilização dos recursos materiais necessários.*

## Referencias

- [1] Isidori, A.: Nonlinear Control Systems, 2nd Edition, Springer Verlag, 1989
- [2] Freund, E.: Decoupling and Pole Assignment in non-linear Systems, *Electronic Letters* 9, S. 373-374, 1973
- [3] Zell, A.: *Simulation Neuronaler Netze*, Addison-Wesley, Bonn, 1995
- [4] Bauchspiess, A.: Servocontrole preditivo de robos guiados por sensores. *Anais do XI CBA*, pp. 1715-1720, Sao Paulo, 1996
- [5] Feedback Inc, MS-150 User Manual, 1979
- [6] Moody, J., Darken, C.J.: "Fast learning in networks of locally tuned processing units", *Neural Computation*, vol. 1, no.2, pp. 281-294, 1989.
- [7] Girosi, F.: "Some extensions of radial basis functions and their application in artificial intelligence", *Computers Math. applic.*, vol. 24, no. 12, pp. 61-80, 1992.
- [8] Bishop, C.M.: "Novelty detection and neural network validation". Preprint (Internet). Reino Unido, Aston University. Department of Computer Science, 1994.
- [9] Jang, J.S., Sun, C.T.: "Functional equivalence between radial basis function networks and fuzzy inference systems". Preprint (Internet). Berkeley, EUA: University of California. Department of Electrical Engineering and Computer Science, 1992.
- [10] Romariz, A.R.S: Representação e Aquisição de Regras em Sistemas conexionistas. Dissertação de Mestrado. Universidade Estadual de Campinas, Campinas, SP, Brasil, 1995.
- [11] Widrow, B., Stearns, S.D.: *Adaptive Signal Processing*. Englewood Cliffs, EUA, 1984.
- [12] Ramos, A.C., Yoneyama, T.: Compensador neuronal para incertezas paramétricas em desacoplador dinâmico de manipuladores mecânicos, X CBA, Vol 2, pp. 903-908, Rio de Janeiro, 19 a 23 de Setembro 1994.
- [13] Bauchspiess, A.; Drummond, A.; Romariz, A.R.S.: Redes Neurais de Base Radial para o Servocontrole Auto-Ajustável de Sistemas Posicionadores, IIICBRN, pp. 472-477, Florianópolis, Julho de 1997
- [14] iNMOs, Ansi C- Transputer Toolset User Guide, 1992.
- [15] Narendra, K.S.: Neural Network for control: Theory and Practice, *Proceedings IEEE*, Vol. 84, Nr. 10, pp. 1385-1406, Oct. 1996.
- [16] Wurmthaler, Ch.: "Prozessmodelle als Grundlagen moderner Regelungskonzepte", Habilitation-Thesis, Universität Erlangen-Nurnberg, 1994.