

# Identificação e Controle de um Sistema de Tanques de duas Colunas usando Redes Neurais Recorrentes e Controlador Preditivo NEPSAC

Francisco Fábio Lobo Freitas, Laurinda Lúcia Nogueira dos Reis,  
Arthur Plínio de Souza Braga, and Antônio Barbosa de Souza Júnior

Universidade Federal do Ceará, UFC, Departamento de Engenharia Elétrica,  
GPAR - Grupo de Pesquisa em Automação e Robótica, Fortaleza-CE, Brasil.  
fflfreitas@yahoo.com.br, {laurinda, arthurp, barbosa}@dee.ufc.br

**Resumo** Sistemas não lineares com múltiplas entradas e múltiplas saídas (MIMO) representam um desafio para o projeto de controladores. Neste trabalho, apresenta-se o uso de um controlador preditivo do tipo NEPSAC-MIMO em um problema de interesse na indústria química: o controle de nível de reagentes em um sistema de tanques com duas colunas. Adota-se uma Rede Neural Recorrente como modelo da dinâmica do sistema de tanques utilizado pelo controlador. Resultados em simulação são apresentados para mostrar o desempenho comparativo do controlador utilizando modelo fenomenológico e a Rede Neural Recorrente.

**Palavras-chave.** Redes Neurais Recorrentes, Sistema de Tanques, Controlador NEPSAC, Identificação de Sistemas

## 1 Introdução

Os sistemas reais de modo geral, principalmente os não lineares, precisam ser modelados de forma mais eficaz para que possam ser controlados em um ponto de operação desejado. Para obter tais modelos, existem vários métodos e o uso de Redes Neurais estão sendo cada vez mais utilizadas para identificação de sistemas não lineares [1].

As redes neurais podem ser classificadas como *feedforward* ou recorrentes. A maioria das publicações de identificação de sistemas não lineares usam redes do tipo *feedforward* como a rede de perceptrons de múltiplas camadas (do inglês, *multilayer perceptrons* - MLP), as quais são implementadas para aproximação de funções não lineares [2] [3]. A principal dificuldade das redes MLP *feedforward* em problemas de identificação está na forma de incorporar informação temporal - normalmente adota-se linhas de atraso na entrada da rede, as quais precisam ser dimensionadas. As redes recorrentes, graças a realimentação, têm uma maior capacidade de representar dinâmicas não lineares em relação às redes *feedforward* [4].

Tais sistemas não lineares precisam ser controlados com eficiência e rapidez, para isso os controladores preditivos baseados em modelo (*MBPC* - "*Model Based Predictive Control*") são uma estratégia bastante aplicadas. O termo MBPC

descreve uma classe de algoritmos computacionais de controle que, a partir de previsões baseadas em um modelo do processo, controla o comportamento futuro através da minimização de uma função objetivo.

A tecnologia MBPC foi originalmente aplicada em sistemas de potência e refinarias petrolíferas. Atualmente, podem ser encontrados MBPCs em uma variedade de ambientes de manufatura, incluindo-se químicos, processamento de alimentos, automotivos, aeroespacial, metalúrgico e fabricação de papel [5], [6]. O controlador (*NEPSAC* - "*Nonlinear Extended Prediction Self-Adaptive Control*"), pertencente à classe dos controladores baseados a modelo, vem sendo bastante estudado no controle de sistemas não lineares, e é utilizado com uma rede recorrente neste artigo.

O objetivo deste trabalho é identificar um sistema de tanques de duas colunas usando uma rede neural recorrente e aplicar neste modelo um controlador preditivo NEPSAC comparando os resultados do controlador usando o modelo neural com o modelo fenomenológico.

Este trabalho está dividido como segue: Na seção 2 temos a descrição do controlador NEPSAC, na seção 3 descrevemos a rede neural recorrente utilizada na identificação, a descrição do sistema de tanques de duas colunas a ser identificado e controlado, as definições de projeto, treinamento e validação da rede neural, na seção 4 mostramos os resultados da identificação neural recorrente com e sem a presença de ruído e do controlador NEPSAC comparando o uso do modelo fenomenológico do sistema com o modelo neural e na seção 5 apresentamos as conclusões do trabalho.

## 2 NEPSAC Multivariável

As equações chaves do NEPSAC para o caso MIMO[7] (Considerando um sistema de duas entrada e duas saídas) são:

$$\begin{cases} Y_1 = Y_{b1} + G_{11}.U_1 + G_{12}.U_2 \\ Y_2 = Y_{b2} + G_{21}.U_1 + G_{22}.U_2 \end{cases} \quad (1)$$

### 2.1 A Função Objetivo

Segundo [8] e [9], para sistemas MIMO, o cálculo dos vetores de controle ótimos  $U_{o1}$  e  $U_{o2}$  podem ser feitos de duas maneiras, dependendo da escolha do critério de controle:

- Controle solidário (do inglês: *solidary control*);
- Controle egoísta (do inglês: *selfish control*).

Utilizaremos neste trabalho o controle solidário.

**Controle Solidário** O objetivo é encontrar os vetores de controle ótimos  $U_{o1}$  e  $U_{o2}$  de forma a minimizar a seguinte função custo.

$$\sum_{k=N_1}^{N_2} [r_1(t+k|t) - y_1(t+k|t)]^2 + \sum_{k=N_1}^{N_2} [r_2(t+k|t) - y_2(t+k|t)]^2 \quad (2)$$

sujeitos a  $u_1(t+k|t) = u_1(t+N_u-1|t)$  e  $u_2(t+k|t) = u_2(t+N_u-1|t)$  para  $k \geq N_u$

Com essa estratégia, os erros do controle preditivo somados sobre todas as saídas do processo são minimizados. Isto implica que o esforço de controle para uma variável específica  $y_1$  pode ser deliberadamente aumentado com o propósito de reduzir o erro de controle para outra variável  $y_2$ . O objetivo é então minimizar o erro de controle total para todas as partes em conjunto, e não apenas minimizar o erro de uma variável separadamente. Daí a escolha para o nome controle solidário.

A expressão (2) escrita na forma matricial pode ser reescrita da seguinte forma:

$$(R_1 - Y_1)^T(R_1 - Y_1) + (R_2 - Y_2)^T(R_2 - Y_2) \quad (3)$$

Definindo as matrizes compostas  $G_1 = [G_{11} \ G_{12}]$  e  $G_2 = [G_{21} \ G_{22}]$  e a matriz composta  $U = [U_1 \ U_2]^T$  e usando a equação chave (1), a função custo (3) se torna:

$$[(R_1 - Y_{b1}) - G_1 \cdot U]^T [(R_1 - Y_{b1}) - G_1 \cdot U] + [(R_2 - Y_{b2}) - G_2 \cdot U]^T [(R_2 - Y_{b2}) - G_2 \cdot U] \quad (4)$$

Note que embora a expressão acima seja composta de matrizes, o resultado da mesma é um escalar. Podendo facilmente ser transformado num índice de custo quadrático considerando a adição da ponderação de controle:

$$J(U) = U^T H U + 2f^T U + \Delta U^T Q_\lambda \Delta U + c \quad (5)$$

com

$$H = G_1^T G_1 + G_2^T G_2 + M^T Q_\lambda M \quad (6)$$

$$f = -[G_1^T (R_1 - Y_{b1}) + G_2^T (R_2 - Y_{b2})] + M^T Q_\lambda (M U_b - U_0) \quad (7)$$

$$\Delta U = M U_o + M U_b - U_0 \quad (8)$$

$$c = (R_1 - Y_{b1})^T (R_1 - Y_{b1}) + (R_2 - Y_{b2})^T (R_2 - Y_{b2}) \quad (9)$$

Minimizando  $J(U)$  fazendo  $(\frac{\partial J(U)}{\partial U} = 0)$  resulta na solução:  $U_o = -H^{-1} f$ :

$$U_o = [G_1^T G_1 + G_2^T G_2]^{-1} [G_1^T (R_1 - Y_{b1}) + G_2^T (R_2 - Y_{b2})] \quad (10)$$

### 3 Redes Neurais Recorrentes

Redes neurais recorrentes (do inglês, *Recurrent neural networks - RNNs*) são referidas dessa forma por terem um ou mais laços de realimentação. As conexões recorrentes podem assumir as seguintes configurações [10] [11]:

- Local: a saída de um neurônio é conectada na entrada dele mesmo;
- Não-Local: é um tipo especial de conexão local, porém é estabelecida entre neurônios distintos e da mesma camada;
- Global: neste caso, a saída de um neurônio de uma camada é conectada à entrada de um neurônio de uma camada anterior.

Uma rede recorrente tem resposta que depende do tempo para um sinal externo aplicado, por isto são chamadas de redes recorrentes dinamicamente direcionadas[10]. O emprego de realimentação permite que a rede recorrente utilize representações de estados. Tornam-se úteis para aplicações como modelagens e previsões não-lineares, equalização adaptativa de processamento de fala, sistemas de controle, diagnóstico de motores de automóveis.

Neste artigo será utilizado o modelo recorrente entrada-saída, também conhecida como redes auto-regressivas não-lineares com entradas exógenas (NARX, *Nonlinear Autoregressive with Exogeneous Inputs*) para modelagem do sistema de tanques de duas colunas.

### 3.1 Rede recorrente NARX

As redes NARX vem sendo utilizadas com sucesso em um amplo conjunto de aplicações de modelagem entrada-saída, demonstrando melhor desempenho que as RNAs recorrentes padrão, apresentando convergência mais rápida e maior capacidade de generalização [10] [12]. A figura 1 mostra um modelo esquemático de uma rede NARX.

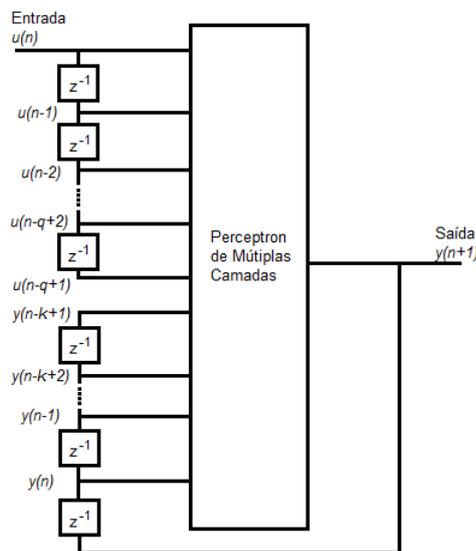


Figura 1: Modelo auto-regressivo não-linear com entradas exógenas (NARX).

Na figura 1, no  $n$ -ésimo passo iterativo de treinamento, a saída  $y(n)$  é dada pela expressão 11, onde  $\Psi()$  é uma função não-linear nos seus argumentos, e  $q$  e  $k$  são os tamanhos das memórias de curto prazo aplicadas à entrada  $x(n)$  e à saída  $y(n)$  respectivamente. Um vetor de entrada apresentado à rede forma uma janela de dados de valores presentes e passados da entrada (dados exógenos) e valores atrasados da saída (dados regredidos) [11].

$$y(n) = \Psi[y(n), y(n-1), \dots, y(n-k+1), x(n), x(n-1), \dots, x(n-q+1)], \quad (11)$$

Com:

$$u(n) = [y(n), y(n-1), \dots, y(n-k+1), x(n), x(n-1), \dots, x(n-q+1)], \quad (12)$$

Na realimentação das saídas desta rede NARX não foram considerados pesos sinápticos, apenas os pesos sinápticos da MLP no sentido *forward*.

### 3.2 Sistema de tanque de 2 Colunas

O tanque de duas colunas possui dois motores-bomba com modulação PWM, onde o ciclo de trabalho é a entrada para identificação. Os níveis dos tanques são as saídas. O sistema possui ainda uma válvula de comunicação entre os dois tanques conforme mostra a figura 2.

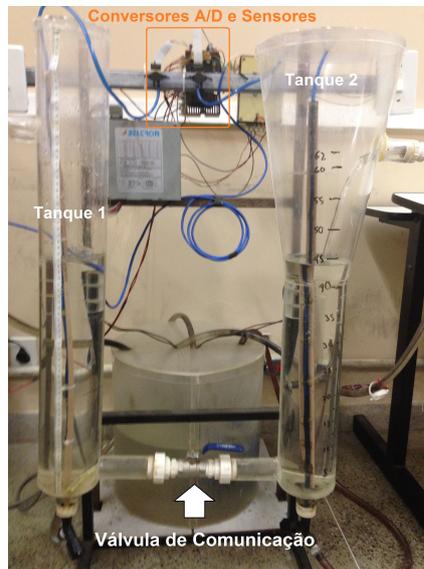


Figura 2: Sistema de tanques de 2 colunas em H

Usando o sistema real da figura 2, aplicamos uma entrada (*PRBS* - "Pseudo Random Binary Sequence") nos 2 tanques, como mostra a figura 3 e efetuamos as leituras dos níveis de líquidos, gerando assim os dados para o treinamento e validação da rede neural recorrente. O software usado para as simulações tanto da rede NARX quanto do controlador NEPSAC foi o MATLAB<sup>®</sup>.

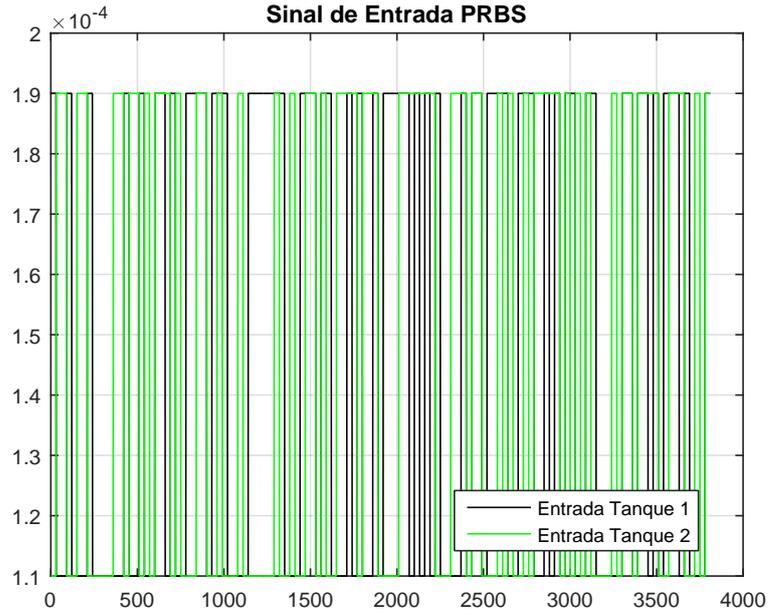


Figura 3: Entrada PRBS

### 3.3 Dados da Rede NARX

A rede neural NARX projetada nesse artigo para a identificação do sistema de tanque de 2 colunas tem as seguintes características:

- Algoritmo de aprendizagem: *Backpropagation*;
- Função de ativação: *Tangente Sigmóide*;
- Taxa de aprendizagem camada escondida: 0,85;
- Taxa de aprendizagem camada de saída: 0,15;
- Camada de entrada: 8 *neurônios*;
- Camada escondida: 20 *neurônios*;
- Camada de saída: 2 *neurônios*;
- 10.000 *iterações*.

A entrada aplicada a rede NARX tem o seguinte formato:

$$x(t) = [y_1(t), y_1(t-1), y_1(t-2), y_2(t), y_2(t-1), y_2(t-2), u_1(t), u_2(t)], \quad (13)$$

## 4 Resultados

### 4.1 Identificação Neural NARX

A identificação do sistema de tanques usando a rede neural recorrente NARX foi feita primeiramente sem ruído e depois introduzimos ruído na saída de cada tanque. Simulamos um ruído da ordem de  $10^{-3}$  na saída de cada tanque. Nas figuras 4(a) e 5(a), mostram respectivamente os resultados da identificação para os casos: sem ruído, com ruído respectivamente. Já nas figuras 4(b) e 5(b) temos os erros percentuais para as cada modelo simulado, ou seja, sem ruído e com ruído respectivamente.

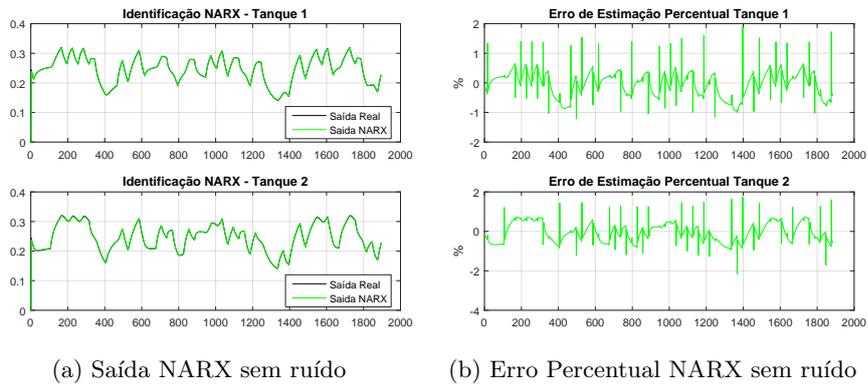


Figura 4: Identificação usando a Rede NARX sem ruído

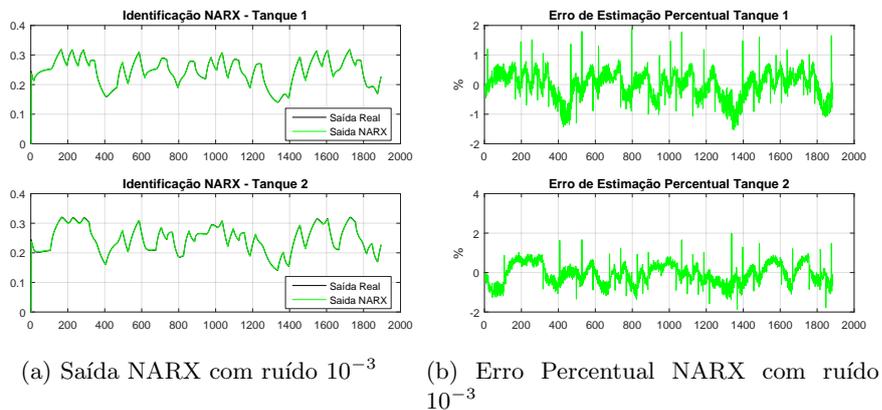


Figura 5: Identificação usando a Rede NARX com ruído  $10^{-3}$

## 4.2 Controlador NEPSAC

Para o teste do controlador foi adotado condições iniciais iguais a zero, isto é, ambas as alturas do tanque valiam zero. Foram testados as respostas dos controladores NEPSAC. O tempo de amostragem foi adotado igual a 0.01s e o tempo de integração foi adotado como um décimo do valor do tempo de amostragem.

Para ambos os controladores (modelo fenomenológico) foram adotados as seguintes configurações: Horizonte de Predição igual a 5, Horizonte de Controle no valor de 1, o valor de ponderação da ação de controle  $\lambda$  foi adotado igual a 0.1, para ambas as entradas e para ambos os controladores o  $u_{base}$  foi adotado como um vetor de valor igual a 0.1 para ambas as entradas e para ambos os controladores.

Nas simulações do controlador NEPSAC usando esses modelos identificados, mostra que mesmo com os modelos neurais com níveis de ruídos da ordem de  $10^{-3}$  o controlador se comporta bem e consegue controlar os níveis de cada tanque.

As Figuras 6, 7 e 8 apresentam a resposta para o controlador NEPSAC usando o modelo matemático sem ruído, usando o modelo neural NARX sem ruído e com ruído da ordem  $10^{-3}$  para ambos os tanques respectivamente.

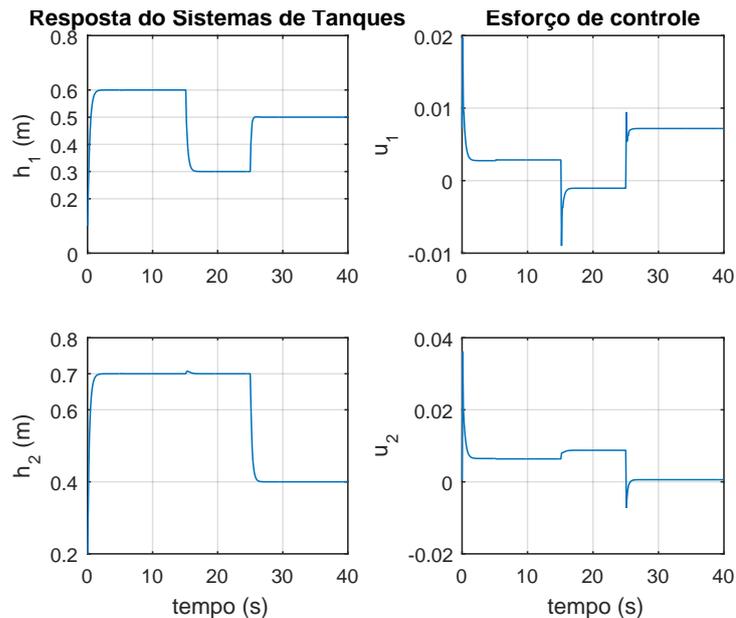


Figura 6: Resposta do NEPSAC - usando Modelo Matemático sem ruído

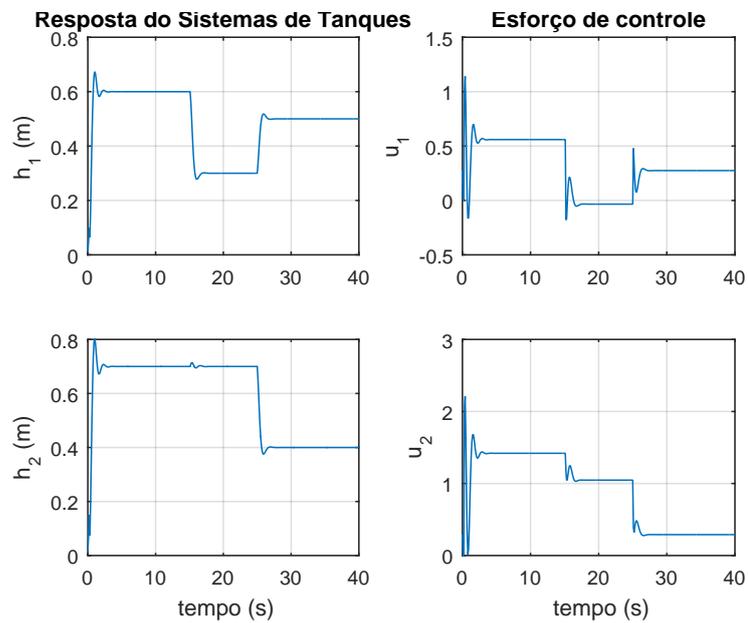


Figura 7: Resposta do NEPSAC - usando Modelo NARX sem ruído

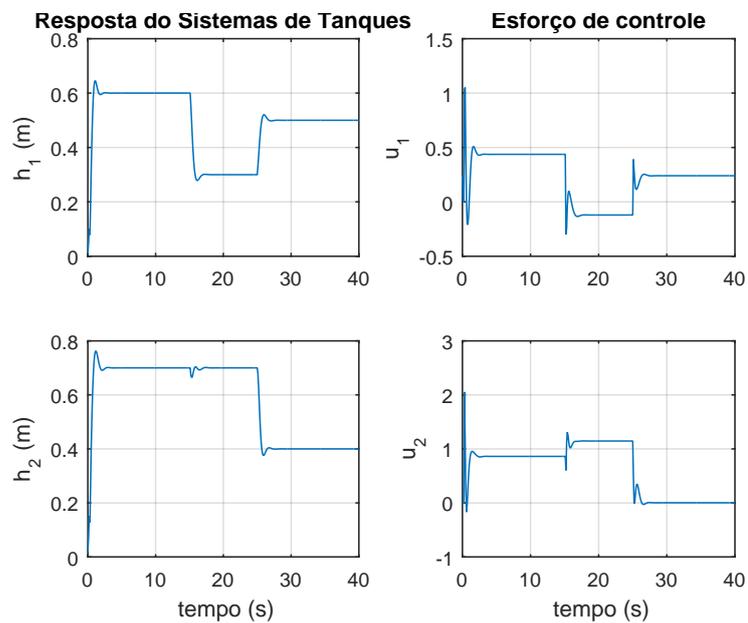


Figura 8: Resposta do NEPSAC - usando Modelo NARX com ruído

## 5 Conclusões

Este trabalho apresentou a simulação de um modelo não linear de um sistema de Tanques. Foi implementado o controlador NEPSAC MIMO usando o modelo do sistema identificado pela rede neural recorrente NARX, que comparado ao modelo fenomenológico se mostrou bastante eficaz devido aos valores de erros percentuais pequenos, aproximadamente 2% como mostrou a figura 5. Verificou-se também que a rede NARX produziu resultados eficazes para identificar o sistema de tanques mesmo com a adição de ruídos nas saídas dos tanques da ordem de  $10^{-3}$ .

Com relação ao controlador NEPSAC, comparando-se os resultados do modelo fenomenológico com os modelos neurais NARX sem ruído e com ruído, vemos que a resposta das curvas das alturas dos níveis de cada tanque (figuras 6, 7 e 8) são muito próximas e as respectivas curvas das variáveis de controle em todas as simulações tem a mesma ordem de grandeza, mostrando assim a eficácia da identificação do sistema usando a rede neural recorrente NARX.

## Agradecimentos

A equipe envolvida nesta pesquisa agradece a Universidade Federal do Ceará, ao CNPQ pelo apoio financeiro através do projeto chamada universal 442573/2014–6 e ao Grupo de Pesquisa em Automação e Robótica (GPAR) da UFC.

## Referências

- [1] Freire, A. L. and de Menezes, J. M. P. and Barreto, G. A.: Redes Neurais Recorrentes para Predição Recursiva de Séries Temporais Caóticas: Um Estudo Comparativo. IX CBRN - Anais do IX Congresso Brasileiro de Redes Neurais, Ouro Preto, Out, (2009)
- [2] Beale, R. and Jackson, T.: Neural Computing: An Introduction. IOP, 1st edition, (1990)
- [3] Bezerra, E. C. and do Rego, M. C. O. and Braga, A. P. de S. and Leão, R. P. S.: Comparação entre modelos estatísticos e redes neurais usando persistência como referência para a previsão da velocidade do vento. X SBAI - Simpósio Brasileiro de Automação Inteligente, São João del Rei - MG, vol. X, 369–374, (2011)
- [4] Yu, W.: Nonlinear system identification using discrete-time recurrent neural networks with stable learning algorithms. Information Sciences, vol. 158, 131–147, (2004)
- [5] Qin, S. J. and Badgwell, T. J.: "An Overview of Nonlinear Model Predictive Control Applications", International Symposium on Nonlinear Model Predictive Control Workshop - Assessment and Future Directions, 1998. Preprints
- [6] Freitas, F. F. L. and Correia, W. B. and Oliveira, D. N. and Almeida, O. da M. and e Silva, J.G.: Aplicação de Controlador Preditivo Baseado em Modelo com Restrições a um Compressor Industrial. VIII Induscon - Conferência Internacional de Aplicações Industriais, Poços de Caldas, MG, 2008

- [7] De Keyser, R. and Lazar, M.: A 'Gent'-le Approach to Nonlinear Predictive Control. The NEPSAC Strategy. Congress of the Automatic Control Association, Medellin, Colômbia, (2013)
- [8] Batista, I. J. L. and Torrico, B. and Barroso, G. C.: Controle Preditivo EPSAC Aplicado ao Rastreamento de Trajetória de Robôs Móveis. XI SBAI - Anais do XI Simpósio Brasileiro de Automação Inteligente , Fortaleza-CE, (2013)
- [9] Medina, R. and Hernandez, A. and Ionescu, C. and De Keyser, R.: Evaluation of Constrained Multivariable EPSAC Predictive Control Methodologies. European Control Conference , Zurich, Switzerland, July, (2013)
- [10] Gomes, L. S.: Redes Neurais Artificiais aplicadas à inferência dos sinais de controle de dosagem de coagulantes em uma estação de tratamento de água por filtração direta. DEE/UFC - Universidade Federal do Ceará, Campus do Pici S/N, Mar, (2012)
- [11] Haykin, S.: Redes Neurais - Princípios e Prática; trad. Paulo Martins Engel. Bookman, 2 edição, Porto Alegre, (2001)
- [12] Ludwig, O. J. and Costa, E. M. M.: Redes Neurais: Fundamentos e Aplicações com Programas em C. Editora Ciência Moderna, (2007)