

# IDENTIFICAÇÃO NEURAL DE UM SISTEMA DE NÍVEIS EM AMBIENTE FOUNDATION FIELDBUS

RAPHAELA GALHARDO FERNANDES\*, DIEGO RODRIGO CABRAL SILVA\*, LUIZ AFFONSO H. GUEDES  
DE OLIVEIRA\*, ADRIAO DUARTE DÓRIA NETO\*

\*Natal, RN, Brazil

Emails: raphaela@dca.ufrn.br, diego@dca.ufrn.br, affonso@dca.ufrn.br,  
adriao@dca.ufrn.br

**Abstract**— Identification is considered one of the most relevant topics in the control theory field. Thus, for linear plants, identification activity can be considered a trivial task, but for non linear plants it is a rather complex activity. This work aims to describe two neural identification approaches applied to a level plant. Both identification strategies are applied to environments that simulate reality. For such task, an infrastructure of industrial network such as Fieldbus Foundation is used. After this process, results are compared and analyzed.

**Keywords**— System Identification. Neural Identification. Neural Network. Foundation Fieldbus.

**Resumo**— Identificação é um dos tópicos mais relevantes na área da teoria de controle. Para plantas lineares, a atividade de identificação pode ser uma tarefa trivial, porém para plantas com natureza não-linear, geralmente, a tarefa é complexa. Este trabalho descreve duas abordagens de identificação neural aplicadas a uma planta de níveis. Ambas estratégias de identificação são aplicadas a ambientes simulado e real, utilizando-se de uma infraestrutura de redes industriais do tipo Fieldbus Foundation. Por fim, os resultados são analisados e comparados.

**Keywords**— Identificação de Sistemas. Identificação Neural. Redes Neurais. Foundation Fieldbus.

## 1 Introdução

A identificação de sistemas constitui-se em um dos problemas básicos na teoria de controle. Para o caso em que a planta possui natureza linear, a identificação pode ser feita através da construção de uma função de transferência que represente o comportamento da mesma, em tempo discreto ou contínuo. Técnicas para identificação de sistemas lineares estão bem consolidadas e com vários resultados teóricos e práticos (Ljung, 1987).

No mundo real, a maioria das plantas é de natureza não-linear e sua identificação se torna bem mais difícil (Billings, 1980), podendo ser feita analiticamente ou computacionalmente.

Identificar analiticamente significa analisar a dinâmica do sistema físico e desenvolver um modelo matemático para ele. Já a identificação computacional é feita a partir de dados observados na entrada e na saída da planta e deve ser representativa do ponto de vista estatístico. Ela pode ser realizada a partir dos seguintes passos:

1. Planejamento Experimental: determinar qual será o método de amostragem para a coleta dos dados;
2. Seleção de Uma Estrutura de Modelo: selecionar a estrutura do modelo e em seguida, determinar os parâmetros livres (parâmetros a serem ajustados);
3. Estimação de Parâmetros: ajustar os parâmetros livres a partir das estatísticas dos dados obtidas;
4. Validação: avaliar o desempenho do modelo para os dados de testes.

Uma das aplicações existentes para a identificação de sistema é relacionada ao projeto de controladores. A idéia geral no projeto de controladores é encontrar um controlador que modifica um dado comportamento de um sistema dinâmico com a finalidade de alcançar alguns objetivos. Mesmo que a estratégia de controle possa ser obtida diretamente, vários métodos de controle baseados na programação dinâmica exigem que a planta seja identificada, ou seja, há a necessidade de um modelo de planta capaz de prever as saídas futuras para sinais de testes, permitindo o ajuste dos parâmetros do controlador (Nepomuceno et al., 2004), (Coelho and Coelho, 1999).

Pode-se também aplicar a identificação de plantas em sistemas de Detecção e Isolamento de Falhas (*Fault Detection and Identification - FDI*) (Naughton et al., 1996), (Shin et al., 2005). Nesses trabalhos, uma Rede Neural Artificial (RNA) é usada para reproduzir o comportamento dinâmico do sistema livre de falhas e a cada instante, a saída do sistema é comparada à saída estimada da RNA, possibilitando informar a ocorrência ou não de falhas.

A cada vez mais os projetistas e engenheiros tendem a lidar com sistemas mais complexos, o que viabilizou a identificação e o controle desses sistemas com o uso de técnicas inteligentes (Nürnberg et al., 2001). Uma estratégia para a identificação inteligente de sistemas não-lineares é utilizar RNA's (Haykin, 2001), afinal as RNA's são ferramentas notáveis para aproximação de funções. As RNA's são utilizadas para identificar sistemas, principalmente, quando: pouco se conhece sobre a planta; a estrutura da planta apre-

senta não-linearidades significativas; somente dados de entrada-saída estão disponíveis.

Este artigo trata de um trabalho desenvolvido para identificar um sistema composto por uma planta de níveis. Duas estratégias de identificação foram utilizadas, ambas usando redes neurais. Os testes foram realizados tanto a partir de simulações matemáticas da planta de níveis quanto em um ambiente real integrado a um ambiente industrial através de refe *Fieldbus*. Vale salientar que, o trabalho descrito a seguir consiste na primeira etapa de um sistema FDI a ser desenvolvido utilizando a mesma planta de níveis.

O artigo está organizado da seguinte forma: nesta seção foram introduzidos conceitos referentes à identificação de sistemas; na próxima seção, aborda-se resumidamente como a identificação de sistemas geralmente é feita utilizando RNA's; em seguida, o ambiente que contém a planta para testes é descrito, assim como as estratégias de identificação implementadas; por fim, são apresentados os resultados obtidos e conclusões sobre o trabalho.

## 2 Arquitetura de Identificação com RNA

A identificação de sistemas utilizando redes neurais pode ser feita com redes estáticas ou dinâmicas. Também não há a necessidade de conhecimento prévio de características da planta, pois a identificação é baseada nos dados de entrada e saída. Dessa forma, a RNA tem a tarefa não trivial de construir uma representação para a planta usando pares entrada-saída extraídos da planta real. Depois que um modelo ótimo é identificado para a planta real, simulações computacionais podem ser realizadas utilizando o modelo ao invés da planta real.

A estrutura de identificação de sistemas utilizando redes neurais é exibida na Figura 1. Os pares de vetores  $u(k)$  e  $y(k)$ , que correspondem as entradas e saídas da planta, respectivamente, são padrões apresentados para a RNA. No caso de identificação de sistemas dinâmicos, as entradas da RNA devem conter também valores atrasados, possibilitando que a rede aprenda a dinâmica do sistema. O sinal de erro é calculado e os pesos da rede são ajustados de forma que  $\hat{y}(k)$  aproxime  $y(k)$  para todo  $u(k)$ . O treinamento é finalizado quando o erro é significativamente pequeno e a RNA obtida pode ser usada como um modelo da planta real.

## 3 Descrição do Ambiente

O trabalho desenvolvido trata da aplicação da técnica de identificação neural de sistemas de uma planta de níveis. Como pode ser visto na Figura 2, a planta de níveis é composta por dois tanques, representando um modelo de segunda or-

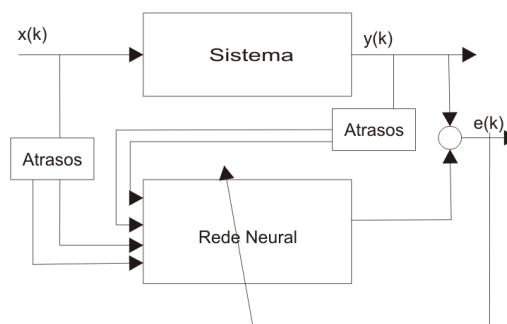


Figura 1: Estrutura Geral de Identificação de Sistemas com RNA

dem com uma entrada. Nessa planta é aplicado uma estratégia de controle Proporcional Integrativo Derivativo (PID), para controlar o nível do tanque 2.

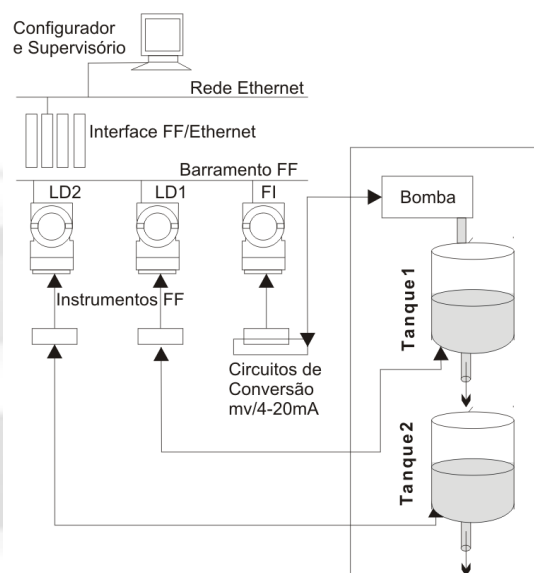


Figura 2: Arquitetura do Ambiente Real

A planta de trabalho, ilustrada na Figura 2, consiste de dois tanques em cascata, isto é, a água que sai pelo orifício do tanque 1 cai dentro do tanque 2. Este por sua vez, também tem um orifício onde a água cai diretamente para o reservatório. Uma bomba é responsável por levar a água do reservatório para o tanque 1. Em cada tanque existe um sensor de pressão *Foundation Fieldbus* (FF) (Lima et al., 2004), usado para medir os níveis correspondentes, ligados à rede *Fieldbus*. Além dos sensores de pressão, um conversor (FF/loop de corrente 4 a 20 mA) é usado para injetar sinais na bomba d'água.

A rede industrial *Foundation Fieldbus* é ligada a um computador supervisor através de interfaces de rede Ethernet. A partir deste computador é realizado todo o processo de configuração dos dispositivos, e o posterior monitoramento.

Os dados reais extraídos da planta para

treinamento das redes neurais também foram extraídos da rede com o auxílio de softwares rodando neste computador. O padrão utilizado para comunicação entre o dispositivo mestre da rede FF e o computador configurador e supervisor é o OPC (*OLE for Process Control*) (Zheng and Nakagawa, 2002). O OPC é responsável por disponibilizar informações sobre o nível dos dispositivos no nível de supervisão para qualquer computador da rede. Além disso, de permitir a alteração de alguns parâmetros de configuração do sistema FF.

A identificação neural foi feita em dois ambientes: simulado e real. Para a simulação do comportamento da planta, utilizou-se o modelo matemático descrito pelas equações 1 e 2.

$$\dot{L}_1 = -\frac{a_1}{A_1} \sqrt{2gL_1} + \frac{K_m}{A_1} V_p \quad (1)$$

$$\dot{L}_2 = -\frac{a_2}{A_2} \sqrt{2gL_2} + \frac{a_1}{A_2} \sqrt{2gL_1} \quad (2)$$

A Tabela 1 apresenta as descrições e valores dos parâmetros mostrados nas equações 1 e 2.

Tabela 1: Parâmetros

Nome	Significado	Valor
$K_m$	Const. da bomba	$4,6(cm^3/s)/V$
$V_p$	Tensão aplicada à bomba	$-22 < V_p < 22$
$a_1$	Diâmetros da saída dos tanques 1 e 2	$0,178139cm$
$A_1$	Área do tanque 1	$15.5179cm^2$
$A_2$	Área do tanque 2	$15.5179cm^2$
$g$	Aceler. gravidade	$980cm/s^2$

O modelo da planta de nível juntamente com o controlador PID está ilustrado na Figura 3.




Figura 3: Planta de Nível com Controlador PID

#### 4 Identificação do Sistema de Níveis

Duas estratégias foram usadas para a identificação neural do sistema de nível e ambas aplicadas ao ambiente simulado e ao ambiente real. Além disso, todas as RNAs utilizadas são do tipo Percéptron de Múltiplas Camadas (MLP) e foram treinadas com o algoritmo da *Backpropagation*. O número de neurônios de suas camadas ocultas foi escolhido aleatoriamente e os neurônios estão totalmente conectados.

Inicialmente, a identificação do sistema foi feita considerando o sistema como um todo, ou seja, uma única RNA foi treinada para gerar o nível do tanque 2. Essa primeira estratégia foi denominada como identificação em um único passo. Assim, a saída da RNA deve corresponder à saída estimada da planta, no caso, o nível do segundo tanque. O treinamento da RNA para essa abordagem está ilustrado na Figura 4.

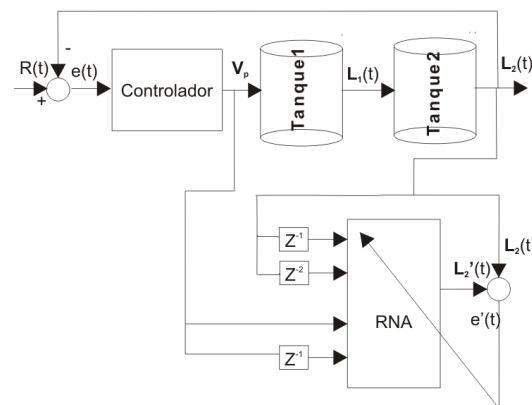


Figura 4: Treino para Determinar Nível do Tanque 2 com Única RNA

A RNA utilizada na identificação em um único passo possui a seguinte arquitetura:

- Quatro nós computacionais na camada de entrada, onde as entradas são:  $V_p(t)$  e  $V_p(t-1)$ ,  $L_2(t-1)$ ,  $L_2(t-2)$ ;
- Uma camada oculta com 5 neurônios com função de ativação sigmóide.
- Um neurônio na camada de saída (função de ativação linear), representando o nível do tanque 2 estimado no instante atual  $t$ ,  $L_2(t)$ .

Como já citado, a identificação da planta de níveis descrita neste artigo é a primeira etapa de um sistema maior de Detecção e Classificação de Falhas na própria planta. Pensando nesta segunda etapa, elaborou-se uma segunda estratégia de identificação que tem função de auxiliar a classificação de falhas. Dessa forma, verificou-se que a identificação neural do sistema seria melhor realizada se fosse feita em dois passos. Em dois passos significa que deve existir uma RNA para estimar o nível do tanque 1 e uma outra para estimar o nível do tanque 2. Os treinamentos das RNAs podem ser ilustrados pelas Figuras 5 e 6.

A arquitetura da RNA 1, usada para estimar o nível do tanque 1, foi:

- Quatro nós computacionais na camada de entrada, onde as entradas são:  $V_p(t)$  e  $V_p(t-1)$ ,  $L_1(t-1)$ ,  $L_1(t-2)$ ;

## 5 Resultados

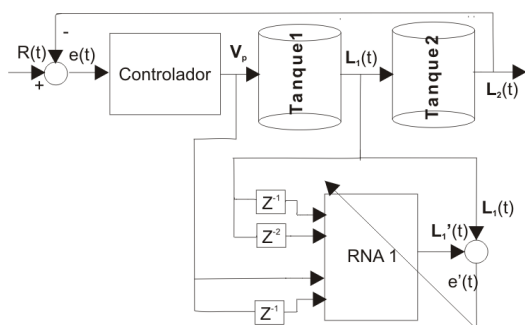


Figura 5: 1ª Etapa: Determinação do Nível do Tanque 1 a partir da Entrada do Sistema

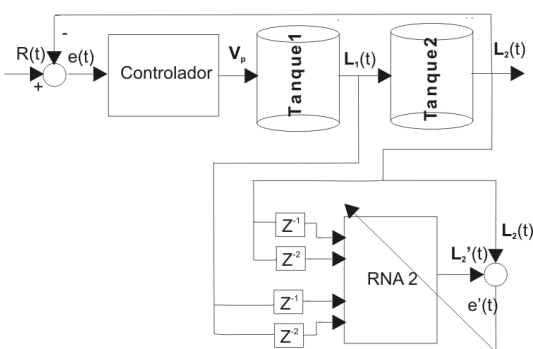


Figura 6: 2ª Etapa: Determinação do Nível do Tanque 2 a partir da Entrada do Sistema

- Uma camada oculta com 4 neurônios com função de ativação sigmóide.
- Um neurônio na camada de saída (função de ativação linear), representando o nível do tanque 1 estimado no instante atual  $t$ ,  $L_1(t)$ .

A arquitetura da RNA 2, usada para estimar o nível do tanque 2, foi:

- Quatro nós computacionais na camada de entrada, onde as entradas são:  $L_1(t - 1)$ ,  $L_1(t - 2)$ ,  $L_2(t - 1)$  e  $L_2(t - 2)$ ;
- Uma camada oculta com 4 neurônios com função de ativação sigmóide.
- Um neurônio na camada de saída (função de ativação linear), representando o nível do tanque 2 estimado no instante atual  $t$ ,  $L_2(t)$ .

Para melhor justificar a identificação em dois passos, em um trabalho futuro pretende-se classificar um conjunto de falhas que podem ocorrer em sensores, atuadores ou no próprio processo. Dessa forma, um importante benefício de se identificar o sistema em dois passos seria que se a saída da RNA 1 divergir da saída real do tanque 1 significa que essas falhas não podem ter ocorrido na parte e sensores do processo que envolve o tanque 2, ou seja, reduzindo as possibilidades na hora de se classificar as falhas.

Como já citado, as estratégias de identificação do sistema de níveis foram aplicadas tanto em ambiente simulado quanto em ambiente real. Como é de se prever, os treinamentos (*offline*) das RNA's foram feitos de acordo com cada ambiente, ou seja, se o treinamento correspondesse ao ambiente simulado, foram utilizados dados simulados a partir do modelo matemático da planta, caso contrário (ambiente real), os dados utilizados foram extraídos da planta real, como explicado na seção 3.

Os resultados da identificação em um único passo são exibidos em dois gráficos. O 1º gráfico mostra os valores do nível do tanque 2 (em cm) ao longo do tempo (em segundos) gerados tanto pela planta quanto pela RNA de identificação. Já o 2º gráfico é um gráfico de erro, que exhibe a diferença em módulo entre o nível do tanque 2 gerado pela planta e a saída gerada pela RNA.

Os resultados da identificação em dois passos são exibidos em três gráficos. O 1º gráfico mostra os valores do nível do tanque 1 (em cm) ao longo do tempo (em seg.) gerados tanto pela planta quanto pela RNA 1 de identificação. O 2º gráfico mostra os valores do nível do tanque 2 (em cm) ao longo do tempo (em seg.) gerados tanto pela planta quanto pela RNA 2 de identificação. Por fim, o 3º gráfico é um gráfico de erro, que exhibe dois erros: um erro que se refere à diferença entre o nível do tanque 1 gerado pela planta e o nível gerado pela RNA 1; e outro erro que se refere à diferença entre o nível do tanque 2 gerado pela planta e o nível gerado pela RNA 2.

Os resultados serão exibidos agrupados por ambiente de testes.

### 5.1 Ambiente Simulado

#### 5.1.1 Identificação Neural em Único Passo

Para os resultados exibidos tanto no ambiente simulado quanto no ambiente real, no 1º gráfico, a curva em azul corresponde aos dados gerados pela planta, já a curva em vermelho aos dados gerados pela saída da RNA. Vale salientar que para ambas as estratégias de identificação foram utilizados os mesmo conjuntos de dados para treinamento.

As Figuras 7 e 8 correspondem aos resultados obtidos pela RNA de identificação em um único passo, considerando os dados simulados pelo modelo matemático da planta de níveis. Observa-se que para ambos os casos, o erro entre a saída gerada pelo modelo simulado e a saída gerada pela RNA é inferior a 0,4 cm.

#### 5.1.2 Identificação Neural em Dois Passos

Para os resultados exibidos tanto no ambiente simulado quanto no ambiente real, nos 1º e 2º gráficos, as curvas em azul corresponde aos dados gera-

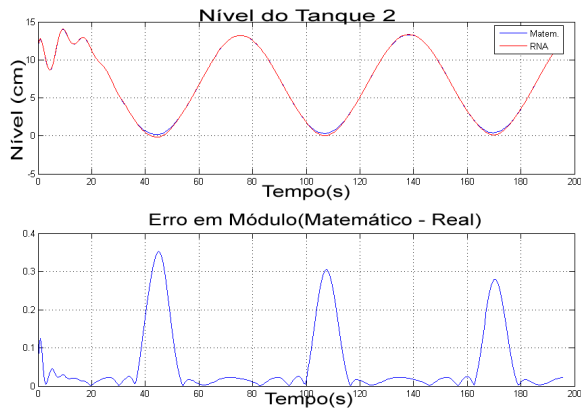


Figura 7: 1ª Abordagem: Resultados com Conjunto de Dados Simulados

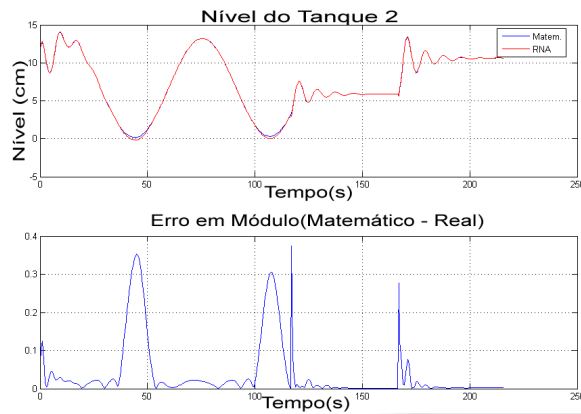


Figura 8: 1ª Abordagem: Resultados com Conjunto de Dados Simulados

dos pela planta, já a curva em vermelho aos dados gerados pela saída da RNA. Em relação ao gráfico de erro, o erro exibido em azul corresponde à diferença entre o nível do tanque 1 e a saída da RNA 1, já o erro em vermelho à diferença entre o nível do tanque 2 e a saída da RNA 2.

Os resultados estão exibidos nas Figuras 9 e 10. Considerando o ambiente simulado, pode-se verificar que o erro obtido utilizando a técnica de identificação em dois passos foi menor do que a técnica de identificação em um único passo.

## 5.2 Ambiente Real

Assim como no treinamento para os dados simulados, os mesmos dados reais foram utilizados para treinar ambas estratégias no ambiente real.

### 5.2.1 Identificação Neural em Único Passo

As Figuras 11 e 12 exibem os resultados de identificação neural no ambiente real para a identificação em um único passo.

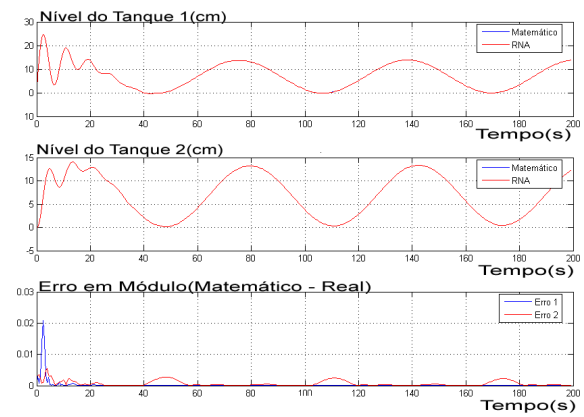


Figura 9: 2ª Abordagem: Resultados com Conjunto de Dados Simulados




Figura 10: 2ª Abordagem: Resultados com Conjunto de Dados Simulados

## 5.2.2 Identificação Neural em Dois Passos

Os gráficos das Figuras 13 e 14 exibem os resultados de identificação neural no ambiente real para a identificação em dois passos.

Da mesma forma que as estratégias de identificação do sistema funcionaram bem considerando o ambiente simulado, os resultados mostram que em ambiente real também é possível aplicar as mesmas estratégias.

## 6 Conclusões e Perspectivas

Neste trabalho foram exibidas duas abordagens de identificação de sistemas utilizando RNA's. Ambas aplicadas tanto em ambiente simulado quanto em ambiente real e produzindo resultados satisfatórios.

Com este trabalho, verificou-se que há diferença significativa quando se trabalha com um ambiente real ao invés do ambiente simulado. Isto deve-se a existência de ruídos e não-linearidades presentes no ambiente real que são geralmente negligenciados em simulações.

Outro aspecto importante neste trabalho foi o emprego de uma infra-estrutura de rede indus-

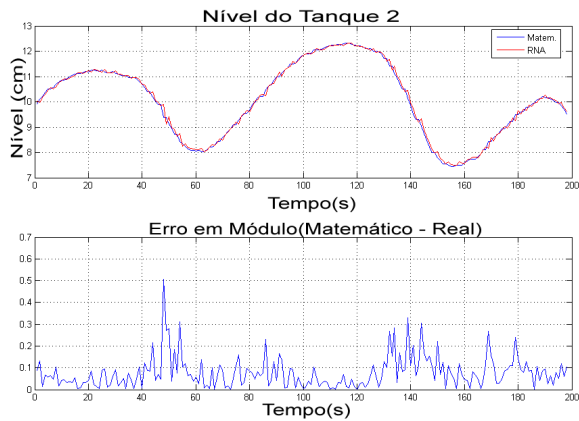


Figura 11: 1ª Abordagem: Resultados com Conjunto de Dados Reais




Figura 12: 1ª Abordagem: Resultados com Conjunto de Dados Reais

trial tipo Foudation Fieldbus integrada ao ambiente real de testes.

Como trabalho futuro, pretende-se utilizar as estratégias de identificação neural apresentadas como uma etapa de um processo de detecção de falhas em sistemas dinâmicos.

### Referências

Billings, S. A. (1980). Identification of nonlinear systems - a survey, *Technical report*.

Coelho, L. S. and Coelho, A. A. R. (1999). Algoritmos evolutivos em identificação e controle de processos: Uma visão integrada e perspectivas, *Technical report*.

Haykin, S. (2001). *Redes neurais: princípios e prática*, 2nd edn, Bookman.

Lima, F., Guedes, L. A., Ortiz, A. and Maitelli, A. (2004). Hybrid environment for tests and training in fieldbuses, *Technical report*.

Ljung, L. (1987). *System Identification: Theory for the user*, Prentice-Hall, Englewood Cliffs, NJ.

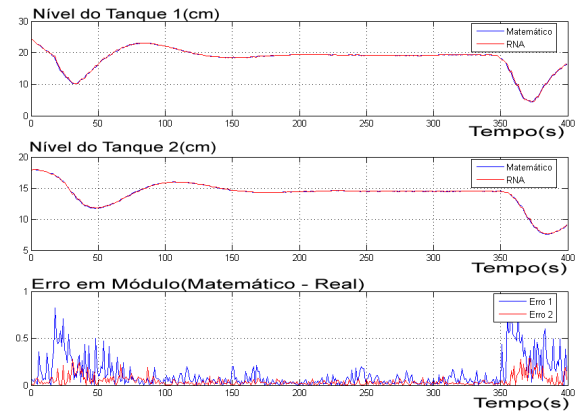


Figura 13: 2ª Abordagem: Resultados com Conjunto de Dados Reais

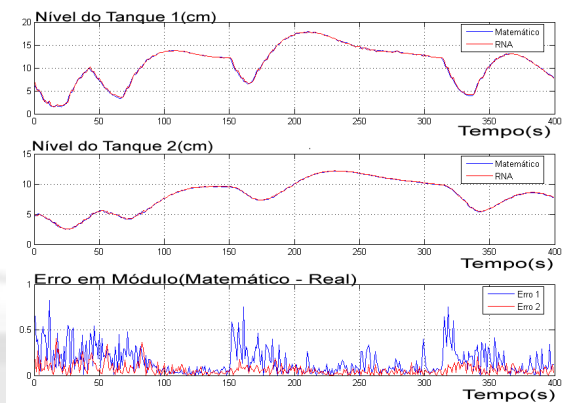


Figura 14: 2ª Abordagem: Resultados com Conjunto de Dados Reais

Naughton, J. M., Chen, Y. C. and Jiang, J. (1996). A neural networks application to fault diagnosis for robotic manipulator, *Technical report*, Ryerson Polytechnic University Toronto and University of Western Ontario London.

Nepomuceno, E., Takahashi, R. H. C., Aguirre, L. A., Neto, O. M. and Mendes, E. M. A. M. (2004). Multiobjective nonlinear system identification: a case study with thyristor controlled series capacitor, *Technical report*.

Nürnbergger, A., Radetzky, A. and Kruse, R. (2001). Using recurrent neuro-fuzzy techniques for the identification and simulation of dynamic systems, *Technical report*.

Shin, H. J., Eom, D.-H. and Kim, S.-S. (2005). One-class support vector machines - an application in machine fault detection and classification, *Computer and Industrial Engineering* pp. 395–408.

Zheng, L. and Nakagawa, H. (2002). Opc (ole for process control) specification and its developments, *Technical report*, 41st SICE Annual Conference.