

DESENVOLVIMENTO E IMPLEMENTAÇÃO DE UMA FERRAMENTA COMPUTACIONAL APLICADA NO PROCESSO DE IDENTIFICAÇÃO DE SISTEMAS EM AMBIENTES FOUNDATION FIELDBUS¹

Márcio José da Cunha²

Dennis Brandão³

Mario Pinotti Junior⁴

Resumo

Técnicas experimentais de Identificação de Sistemas têm despertado interesse na indústria, devido a sua facilidade em se ajustar modelos matemáticos, facilitando a formulação e a resolução de problemas de controle de processos. É proposto um aplicativo computacional, o Sintonizador, baseado em uma técnica experimental de Identificação de Sistemas, utilizando a estrutura matemática linear ARX. Os parâmetros da estrutura matemática ARX são estimados por meio do método dos Mínimos Quadrados Recursivo (RLS). A comunicação e a aquisição de dados de redes *fieldbus* é feita através do padrão de comunicação OPC.

Palavras-chave: Identificação de sistemas; Foundation Fieldbus; OPC.

DEVELOPMENT AND IMPLEMENTATION OF A COMPUTATIONAL TOOL APPLIED TO THE SYSTEM IDENTIFICATION PROCESS IN A FOUNDATION FIELDBUS ENVIRONMENT

Abstract

Experimental system identification techniques are considered interesting by industrial sector due to the simple approach to adjust mathematical models, making it easy the formulation and the solution of process control problems. In this work a computational tool is proposed, the Sintonizador, based on the experimental technique of System Identification, using the linear mathematical structure ARX (Auto-Regressive with eXogenous inputs). The ARX structure parameters are estimated by RLS (Recursive Least Square) algorithm. The data communication and data acquisition of the fieldbus network has been done through of the OPC communication standard.

Key words: System identification; Foundation Fieldbus; OPC.

¹ Contribuição técnica ao 62º Congresso Anual da ABM – Internacional, 23 a 27 de julho de 2007, Vitória – ES, Brasil.

² Aluno de Doutorado em Engenharia Mecânica da Escola de Engenharia de São Carlos – Universidade de São Paulo.

³ Professor Departamento de Engenharia Elétrica da Escola de Engenharia de São Carlos – Universidade de São Paulo.

⁴ Professor Departamento de Engenharia de Materiais, Aeronáutica e Automobilística da Escola de Engenharia de São Carlos – Universidade de São Paulo.

1 INTRODUÇÃO

As técnicas de modelagem de sistemas são um tipo de modelagem matemática, onde estas são utilizadas para descrever a dinâmica de um sistema, importante para o desenvolvimento de sistemas de controle.^[1] Os modelos matemáticos são obtidos através de dois modos: o primeiro modo, o analítico, conhecido também como modelagem teórica, é constituído por um modelo matemático formado por uma ou mais equações diferenciais e (ou) equações algébricas.^[2] O segundo modo, o experimental baseia-se em um modelo matemático obtido através de experimentos com informações de entrada e saída de um determinado processo dinâmico real, e tal modelo é representado por meio de equações diferenças. Um modelo analítico é composto por descrições físicas do sistema, isto é, o modelo é descrito com base nas leis teóricas (leis da mecânica, leis da física, leis da termodinâmica, etc) e leis empíricas necessárias para descrever o comportamento dinâmico do sistema, de modo que tal abordagem permite derivar modelos que descrevem a dinâmica interna do sistema, além da relação entrada-saída.^[3] Esse tipo de modelagem também é conhecido como modelagem caixa-branca,^[4] pois descreve o comportamento dinâmico de um fenômeno ou de um sistema por aproximações analíticas, através de equações constitutivas. Sua principal vantagem está no fato do modelo possuir uma interpretação física clara. Em contra partida, como ressalta,^[2] este tipo de modelo possui algumas desvantagens em relação à complexidade de sua estrutura, ou seja, esse modelo pode envolver dezenas ou até de centenas de equações constitutivas, e geralmente esses modelos são contínuos no tempo, ao passo que as variáveis de saída dos sistemas e ações de controle são discretas no tempo. Esse tipo de modelagem, por ser a mais tradicional, apresenta diversas dificuldades em relação ao tratamento de sistemas mais complexos, não-lineares, estocásticos ou variantes no tempo. Assim, a construção de modelos analíticos para sistemas dessa natureza é geralmente uma tarefa árdua, devido ao seu custo tanto para desenvolvimento quanto computacional.^[5]

A modelagem pelas leis físicas de um sistema pode ser um processo complicado; quando o sistema torna-se grande, complexo ou quando aumenta a complexidade nas interações das variáveis do sistema, dificultando assim a sua descrição matemática. Conseqüentemente, conforme a complexidade do sistema aumenta, a precisão de um modelo utilizado para descrever o sistema com rigor fica restrita, diminuindo sua precisão no decorrer do processo.^[3]

Paralelamente a essas dificuldades citadas, a indústria tem demonstrado interesse em adquirir autonomia nos processos de produção. Porém existem algumas questões relativas à complexidade crescente dos processos de produção que contradizem tal autonomia, como apresentado anteriormente.^[5]

No modo experimental de modelagem, também conhecido como modelagem experimental ou como Identificação de Sistemas é necessária a realização de experimentos e um modelo matemático é obtido através das informações de entrada e saída coletadas, em contraste com a modelagem analítica, onde esta é feita baseada em relações matemáticas e o conhecimento teórico do sistema ou do fenômeno a ser identificado.^[6] Através da técnica de Identificação de Sistemas, não se faz necessário o conhecimento físico e ou teórico do sistema a ser

identificado, pois o modelo matemático é obtido através de dados experimentais de entrada e saída do sistema a ser identificado, por isso o modelo pode ser classificado como um modelo do tipo caixa-preta. Modelos do tipo como caixa preta são ignorados os estados interiores.^[5,7,8]

Uma das grandes vantagens desta técnica é a facilidade em se ajustar o modelo matemático, facilitando a formulação e a resolução de problemas de controle de processos. Porém os parâmetros processados na Identificação de Sistemas não possuem significados físicos, caracterizando-se assim uma desvantagem.^[2]

2 TÉCNICA EXPERIMENTAL DE IDENTIFICAÇÃO DE SISTEMAS

Conceitualmente, a identificação de sistemas é um procedimento simples; com base nos sinais de entrada $u(k)$ e nos sinais de saída real de um sistema a ser identificado $y(k)$, um modelo matemático será obtido, e este será responsável por representar o comportamento do sistema a ser identificado, seja ele total ou de forma aproximada,^[9] conforme na Figura 1:

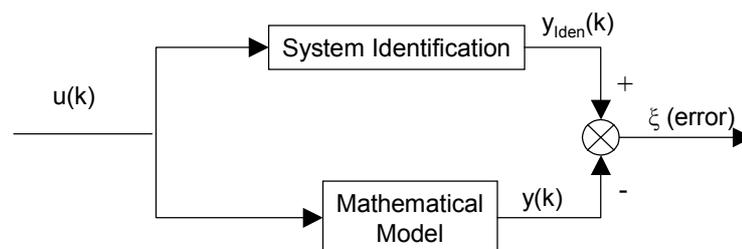


Figura 1. Representação de um sistema Dinâmico.

A seqüência de etapas da Identificação de Sistemas pode ser apresentada da seguinte maneira:^[3,5,9]

- Testes dinâmicos e aquisição de dados;
- Aplicação de testes aos dados obtidos para detecção de não-linearidades;
- Escolha da representação da estrutura matemática;
- Determinação da estrutura de modelo;
- Estimação paramétrica;
- Validações do modelo identificado.

As etapas acima apresentadas são implementadas tanto para sistemas lineares quanto para sistemas não-lineares, sendo que as principais diferenças entre eles se devem à forma como cada procedimento é implementado. Este trabalho, no entanto tem aplicação somente em sistemas lineares. Aplicações com sistemas não-lineares podem ser encontrados em Rodrigues,^[3] Paiva^[5] e Aguirre.^[9]

O fluxograma com a representação do ciclo de Identificação de Sistemas é apresentado na Figura 2:^[5]

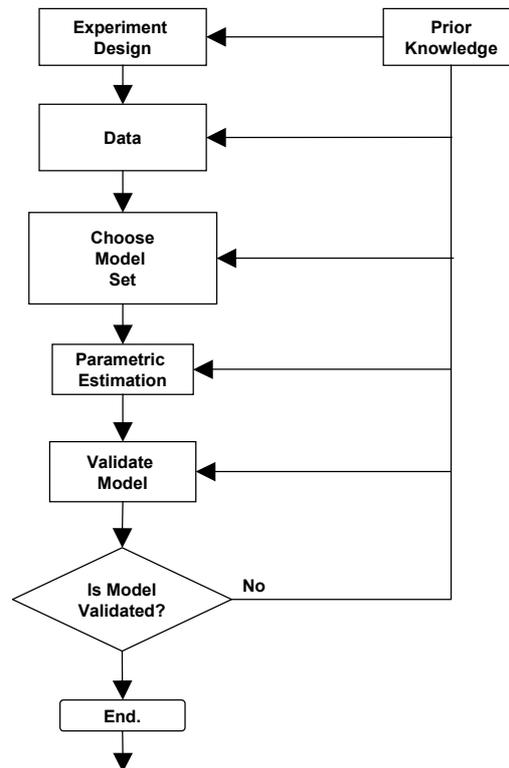


Figura 2. Ciclo do Processo de Identificação de Sistemas

Nas próximas subsecções, são descritos os procedimentos utilizados na Identificação de Sistemas.

2.1 Testes Dinâmicos e Aquisição de Dados

Nessa etapa, são obtidos os dados experimentais do sistema a ser identificado. Portanto é de grande importância se definir bem quais são os passos necessários, tais como a aplicação e manipulação das entradas pré-determinadas utilizadas, o tempo de amostragem, a decisão quanto ao número de amostras adquiridas e o pré-processamento dos dados amostrados.

Os sinais de entradas a serem utilizados para excitar o sistema devem ser projetados para satisfazer determinadas propriedades, ou seja, os sinais de entrada devem possuir um espectro de frequência adequado para excitar os diversos constituintes da planta, garantindo assim a adequabilidade dos dados obtidos.^[3]

2.2 Aplicação de Testes aos Dados Obtidos para Detecção de Não-Linearidades

Todos os sistemas reais em ultima instância são não-lineares, pois a não-linearidade existe mesmo sendo de uma forma bem suave, o que torna possível sua representação por de modelos lineares. Este autor utiliza técnicas para testar as não-linearidades de um sistema baseado no método da correlação cruzada

não-linear, porém no presente trabalho não serão discutidas tais técnicas de detecção de não-linearidades, pois este lida somente de estruturas lineares.^[3] Ainda não existe base na literatura para a identificação de sistemas não-lineares, exigindo assim uma melhor atenção para os testes de não-linearidade.

2.3 Escolha da Representação da Estrutura Matemática

Nesta etapa, é feita a escolha de qual modelo matemático utilizar para a descrição do sistema. Tal escolha deve ser fundamentada no conhecimento do processo de identificação, bem como no conhecimento *à priori* sobre o sistema a ser identificado. De fato, os modelos matemáticos como foi visto anteriormente, são utilizados para se descrever as propriedades de um sistema, sejam essas em partes ou de forma aproximada, o que explicaria a relação do modelo a ser identificado com os dados experimentais.^[9] Por esse fato, essa etapa é considerada como uma das mais importantes no processo de Identificação de Sistemas.

Um modelo linear polinomial pode ser representado pela seguinte estrutura, conforme (1):

$$y(k) = \sum_{i=1}^n \varphi_i^T(k) \theta_i + e(k) \quad (1)$$

onde:

- φ é definido como o vetor de regressores contendo os valores experimentais de entrada e saída do sistema a ser identificado, conforme (2):

$$\varphi = [y(k-1) \text{ K } y(k-na) \quad u(k-1) \text{ K } u(k-nb)] \quad (2)$$

onde $y(k)$ e $u(k)$ são respectivamente os sinais de saída(s) e entrada(s), na representa a quantidade de regressores de saída e nb a quantidade de regressores de entrada;

- θ é definido como o vetor com os parâmetros que devem ser estimados de acordo com a estrutura escolhida;
- $e(k)$ é definido como o erro de predição, definido pela diferença entre as respostas do sistema identificado com o sistema real.

2.4 Determinação da Estrutura de Modelo

Ao final da escolha da representação a ser utilizada são determinados, para sistemas lineares, a quantidade de pólos e zeros e o atraso puro do sistema. Já para sistemas não-lineares, deve-se verificar e determinar a quantidade de termos dos modelos polinomiais, uma vez que o número de termos dos modelos polinomiais cresce de acordo com a não-linearidade.

2.5 Estimação Paramétrica

Nesta etapa são estimados os parâmetros da estrutura matemática escolhida, estrutura esta responsável por representar o comportamento do sistema dinâmico a ser identificado. Na estrutura matemática apresentada em (1),

φ define os regressores do modelo, que correspondem aos diferentes termos no polinômio, θ seus respectivos parâmetros e $e(k)$ o erro de predição, calculado pela diferença entre a resposta do sistema a ser identificado e o sistema real.

Seja o sistema *SISO* (*Single Input Single Output*) representado na Figura 1. O algoritmo dos Mínimos Quadrados é utilizado para calcular os parâmetros θ a cada amostra $y(k)$, tendo como base amostras obtidas quando o sistema estava em funcionamento, processadas em batelada em um segundo momento (*off line*). Podemos expressar a equação (1), pela equação diferença, conforme (3):

$$y(k) = a_1 y(k-1) + a_2 y(k-2) + \dots + a_{na} y(k-na) + b_1 u(k-1) + b_2 u(k-2) + \dots + b_{nb} u(k-nb) \quad (3)$$

onde a e b são os parâmetros do sistema a ser identificado, e $y(k)$ e $u(k)$ são os dados experimentais obtidos do sistema. Os termos na e nb definem a ordem da equação. Escrevendo a equação (3) na forma matricial, obtém-se a equação (4), onde n representa o número mínimo de amostras necessárias para iniciar o processamento através das equações diferenças e N representa a grandeza total de amostras consideradas:

$$\begin{bmatrix} y_p(n) \\ y_p(n+1) \\ \mathbf{M} \\ y_p(N) \end{bmatrix} = \begin{bmatrix} y(n-1) & \mathbf{L} & y(0) & u(n-1) & u(0) \\ y(n) & \mathbf{L} & y(1) & u(n) & u(1) \\ \mathbf{M} & \mathbf{L} & \mathbf{M} & \mathbf{M} & \mathbf{M} \\ y(N-1) & \mathbf{L} & y(N-n) & u(N-1) & u(N-1) \end{bmatrix} \begin{bmatrix} a_1 \\ \mathbf{M} \\ a_{na} \\ b_1 \\ \mathbf{M} \\ b_{nb} \end{bmatrix} + \begin{bmatrix} e(n) \\ e(n+1) \\ \mathbf{M} \\ e(N) \end{bmatrix} \quad (4)$$

A partir da equação (4), define-se (5), (6), (7) e (8) como:

$$Y = \begin{bmatrix} y_p(n) \\ y_p(n+1) \\ \mathbf{M} \\ y_p(N) \end{bmatrix}_{N-n+1 \times (1)} \quad (5)$$

$$\Psi \equiv \begin{bmatrix} y(n-1) & \mathbf{L} & y(0) & u(n-1) & \mathbf{L} & u(0) \\ y_p(n) & \mathbf{L} & y(1) & u(n) & \mathbf{L} & u(1) \\ \mathbf{M} & \mathbf{L} & \mathbf{M} & \mathbf{M} & \mathbf{L} & \mathbf{M} \\ y(N-1) & \mathbf{L} & y(N-n) & u(N-1) & \mathbf{L} & u(N-1) \end{bmatrix}_{(N-n+1) \times (2n)} \quad (6)$$

$$\Theta \equiv \begin{bmatrix} a_1 \\ \mathbf{M} \\ a_{na} \\ b_1 \\ \mathbf{M} \\ b_{nb} \end{bmatrix}_{(2n) \times (1)} \quad (7)$$

$$E \equiv \begin{bmatrix} e(n) \\ e(n+1) \\ \mathbf{M} \\ e(N) \end{bmatrix}_{(N-n+1) \times (1)} \quad (8)$$

Escrevendo (4) de forma compacta, tem-se:

$$Y(k) = \Psi(k)\Theta + E(k) \quad (9)$$

onde as variáveis são definidas:

- Y - Vetor linha das medidas do sistema;
- Θ - Vetor coluna dos parâmetros estimados;
- Ψ - Matriz linha contendo os regressores, obtidos através das medidas de entrada e saída amostradas;
- E - Vetor coluna contendo o erro entre a resposta real e a resposta estimada;

Definindo-se o funcional J como erro quadrático médio, tem-se a equação (10):

$$J = \frac{1}{2} \sum_{k=n}^N e^2(k) \quad (10)$$

ou na forma matricial em (11):

$$J = \frac{1}{2} E^T E \quad (11)$$

Para se evitar a necessidade de se calcular os Mínimos Quadrados novamente a cada amostra adquirida, é necessário atualizar meramente a prévia da estimação calculada no tempo $\Theta(k)$, para obter uma nova estimação $\Theta(k+1)$. Portanto, o vetor Θ , definido em (7) será processado recursivamente para cada conjunto de n amostras, a partir de uma suposição inicial de um vetor de parâmetros, com pelo menos a quantidade mínima de parâmetros necessária para processar a primeira interação, obtendo-se um novo vetor Θ para cada amostra. Deste modo, a resposta atual do algoritmo é uma previsão baseada em parâmetros processados pela planta, com o sistema em funcionamento, caracterizando o processamento on-line. Este método é conhecido como Mínimos Quadrados Recursivo (MQR).^[5] Desta forma, obtêm-se a equação (12):

$$Y(k) = \Psi(k)\Theta(k-1) \quad (12)$$

Inicialmente, pode-se obter um valor alto para o erro, dependendo do conjunto de parâmetros iniciais escolhidos. Para solucionar tal problema, recomenda-se trabalhar com a ordem correta do sistema a ser identificado, assim, teoricamente, o erro tenderá a zero, realizando a convergência da saída aproximada para a saída real do sistema, conforme (13):

$$Y(k) = \Psi(k-1)\Theta(k-1) + E(k-1) \quad (13)$$

Aplicando os procedimentos de minimização do erro quadrático em (10) e (11) para o método dos Mínimos Quadrados, obtém-se a seguinte equação (14):

$$\Theta^{N+1} = \Theta^N + K_{N+1}(Y^{N+1} - \Psi^{N+1}\Theta^N) \quad (14)$$

onde as variáveis são definidas como:

- Θ^{N+1} – Vetor coluna $(2n) \times (1)$ dos parâmetros estimados;
- Θ^N – Matriz coluna $(2n) \times (1)$ dos parâmetros estimados anteriores;
- K_{N+1} – Vetor $(2n) \times (1)$ de ganho de Kalman,^[5] contendo as ponderações a serem aplicadas no vetor Θ . O vetor de ganho de Kalman é definido em (15):

$$K_{N+1} = \frac{(\Psi^{NT}\Psi^N)^{-1}\Psi^{N+1T}}{\left[1 + \Psi^{N+1}(\Psi^{NT}\Psi^N)^{-1}\Psi^{N+1T}\right]} \quad (15)$$

- Y^{N+1} – Escalar com a medida atual da saída;
- Ψ^N – Matriz linha $(1) \times (2n)$ contendo as medidas de entrada e saída anteriores a Ψ^{N+1} ;
- E – Vetor coluna contendo o erro entre a saída real e a saída estimada.

2.6 Validações do Modelo Identificado

Para se validar o modelo identificado é necessário constatar se este incorpora ou não as características de interesse do sistema original. Assim, é de grande importância se comparar os modelos entre si e decidir se há algum candidato melhor.^[9]

Esta comparação é em suma uma etapa subjetiva e o resultado dependerá da aplicação pretendida para o modelo e da quantidade de informação disponível sobre o sistema original. A verificação e a validação do modelo candidato é feita comparando-se as saídas do modelo com as respostas do sistema real para um conjunto de sinais de entrada.^[3,10]

Dentre as diversas formas de se validar um modelo identificado, pode-se destacar o Teste Cruzado e o Teste de Linearidade.^[9]

No Teste Cruzado, são utilizadas duas séries diferentes de dados, e estimam-se parâmetros para o primeiro conjunto de dados. Assim a saída é calculada para o segundo conjunto de dados usando os parâmetros estimados do primeiro conjunto de dados.

Na validação pelo Teste de Linearidade, os ensaios experimentais devem ser repetidos com outras amplitudes do sinal de entrada, introduzindo um sinal de excitação (ex. degrau ou impulso) de amplitude positiva e uma negativa, para verificar os limites do modelo identificado, para diferentes condições de operação.

3 O SINTONIZADOR

O software Sintonizador apresentado neste trabalho é uma ferramenta desenvolvida na plataforma de programação da *Borland*® o *Delphi Vs 6.0*, para sistemas operacionais *Windows*. O Sintonizador é uma aplicação do tipo cliente *OPC*, e foi desenvolvida seguindo as normas para o desenvolvimento de aplicações cliente *OPC* da *OPC Foundation*.^[11]

Dentre algumas características importantes do Sintonizador é de ser uma ferramenta aberta de comunicação com diversas bases de dados do tipo *OPC*, e também como ferramenta de apoio para o desenvolvimento e configuração de estratégias de controle.

3.1 Aplicação do Sintonizador no Processo de Identificação de Sistemas em Ambientes Fieldbus

Nos testes de campo foram utilizados dois sistemas, um sistema dinâmico térmico e um túnel de aquecimento.

O sistema térmico dinâmico é composto por um forno elétrico, instrumentado com transmissores Foundation Fieldbus. Para tal, foram utilizados um transmissor de temperatura, e um conversor fieldbus – 4 a 20ma. O esquema do sistema está representado na Figura 3:

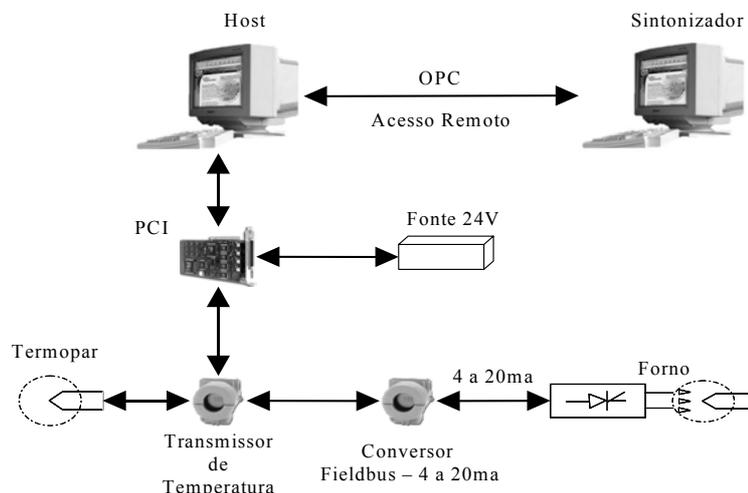


Figura 3. Forno Elétrico

No forno elétrico, o transmissor de temperatura está ligado a um termopar do tipo K, responsável por medir a temperatura interna do forno e o conversor de *fieldbus* para 4 a 20ma aciona uma chave estática, que alimenta a resistência

elétrica que fornece potência ao forno. Os transmissores estão dispostos em um canal *fieldbus*, ligado a uma placa de interface PCI302.

O transmissor de temperatura está ligado a um termopar do tipo K, responsável por medir a temperatura interna do forno e o conversor de *fieldbus* para 4 a 20mA aciona uma chave estática, que alimenta a resistência elétrica que fornece potência ao forno. Os transmissores estão dispostos em um canal *fieldbus*, ligado a uma placa de interface PCI302.

Nos experimentos, o Sintonizador estabelece uma conexão remota com o servidor *OPC* que está conectada a rede *fieldbus* em outra máquina.

A potência em regime de 20%, igual a 7,2 mA a uma temperatura de 52,15 °C, foi excitada com o aumento de potência de 20% para 50%, de 7,2 mA para 12 mA, estabilizando em 128,2 °C. A duração do ensaio foi de 11,1 minutos com uma taxa de amostragem de 0,1 segundos. A resposta do forno é ilustrada na Figura 4:

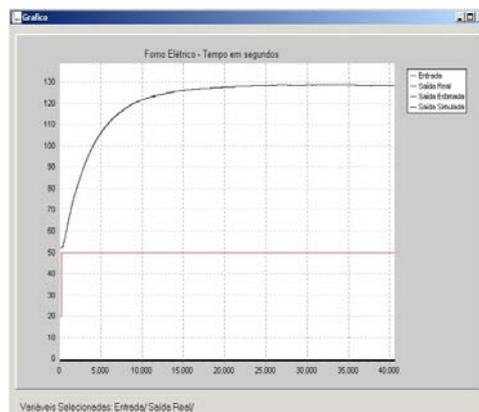


Figura 4 – Resposta Dinâmica do Forno Elétrico.

Os parâmetros calculados pelo Sintonizador a partir dos dados experimentais do Forno Elétrico estão na equação (16):

$$\theta = \begin{pmatrix} 0,9555 & 5,69E-05 & 0,04737 \\ L & L & L \\ 8,475E-06 & 1,7871E-09 & 0,0006704 \end{pmatrix} \quad (16)$$

A partir de (16), obtêm-se a função de transferência em (17) e o modelo *ARX* em :

$$\frac{U}{Y}(z) = \frac{8,475E-6z^2 - 1,7871E-9z + 0,0006704}{z^3 - 0,955z^2 - 5,69E-5z - 0,0437} \quad (17)$$

$$\begin{aligned} y(k) &= 0,955y(k-1) + 5,69E-05y(k-2) \\ &+ 0,0437y(k-3) + 8,475E-06u(k-1) \\ &- 1,7871E-09u(k-2) + 0,0006704u(k-3) \end{aligned} \quad (18)$$

A Figura 5 ilustra a validação feita comparando a resposta gerada pelo modelo identificado com a resposta do forno elétrico, para o mesmo sinal de entrada:

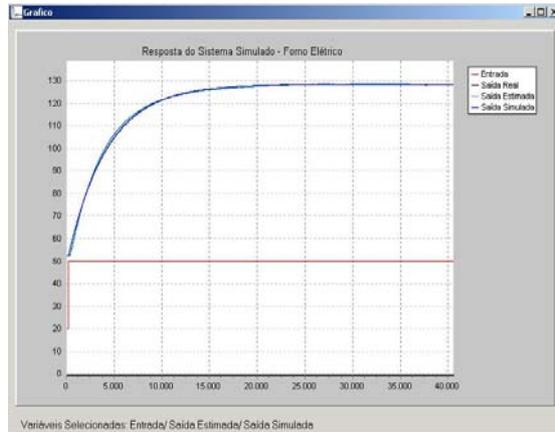


Figura 5. Sistema Identificado a partir dos dados do Forno Elétrico.

O erro quadrático médio, conforme(11), calculado entre a resposta do modelo identificado e a resposta do forno elétrico, é ilustrado na Figura 6:

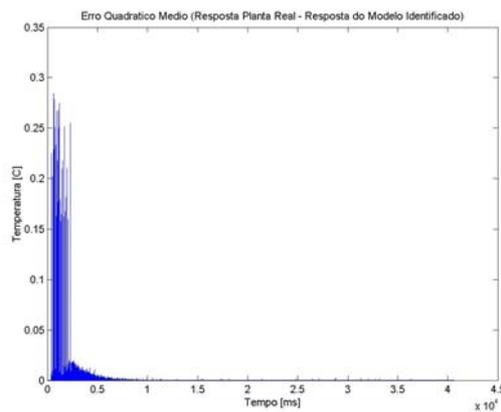


Figura 6. Erro Quadrático calculado entre a Resposta Identificada e a Resposta Real do Forno Elétrico.

Observa-se que o erro quadrático inicialmente obtido em todos os ensaios apresenta um valor inicial relativamente alto. Entretanto, trabalhando com a ordem correta do sistema, teoricamente esse erro tenderá a decrescer a um valor ínfimo com a evolução do número de iterações, realizando a convergência entre a resposta simulada para a resposta real do sistema.

4 CONCLUSÃO

Este trabalho apresentou e exemplificou uma alternativa para o usuário de um sistema de instrumentação *Foundation Fieldbus* viabilizar o projeto de novas estratégias de controle.

A finalidade da Identificação de Sistemas dinâmicos em tempo real é o estudo e o desenvolvimento de estratégias de controle adaptativas aplicadas ao ambiente *Foundation Fieldbus*. O procedimento de validação mostrou que a

convergência do algoritmo de estimação paramétrica proposta é imune aos ruídos de medição da planta. Este resultado viabiliza o uso do aplicativo proposto em estratégia adaptativas de controle para sistemas dinâmicos lentos sem a perda da precisão da estimação paramétrica em regime permanente de operação da planta.

Agradecimentos

Os autores gostariam de agradecer a CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pelo auxílio financeiro, e à Escola de Engenharia de São Carlos da Universidade de São Paulo pelo apoio acadêmico e pela adequada estrutura de pesquisa. Em especial Coordenadoria de Eventos e Publicações da ABM, pelo auxílio concedido.

REFERÊNCIAS

- 1 M. Iwase, H. Iikubo, S. Hatakeyama, K. Furuta “*An Identification Method for Continuous-Time Transfer Functions Based on Nonlinear Optimization*”, in Proc. 28TH Annu. Industrial Electronics Society, Tokyo, 2002, pp. 1978-1983.
- 2 S. C. Santos, “*Identificação Multivariável Aplicada aos Processos Químicos*” M. S. thesis, Federal University of São Carlos, São Carlos, Brazil, 2000.
- 3 G. G. Rodrigues, “*Identificação de Sistemas Dinâmicos Não-Lineares Utilizando Modelos NARMAX Polinomiais – Aplicação a Sistemas Reais.*” M.S. thesis, University of Minas Gerais, Belo Horizonte, Brazil, 2000.
- 4 K. M. Bossley, “*Neurofuzzy Modelling Approaches in System Identification*”, Ph.D thesis, University of Southampton, Southampton, United King, 1997.
- 5 R. P. P. C. Paiva, “*Identificação Neuro-Difusa – Aspectos de Interoperabilidade*” M.S. thesis, University of Coimbra, Coimbra, Portugal, 1999.
- 6 L. Ljung, System Identification – Theory for the Users, Englewood, Prentice Hall.
- 7 J. Sjöberg, H. Hjalmarsson, L. Ljung, “*Neural Networks in System Identification*”, In: Procs Of The 10th Ifac Symposium On System Identification, 1994, pp. 207-212.
- 8 S. Simani, C. Fantuzzi, S. Beghelli, “*Diagnosis Techniques for Sensor Faults of Industrial Processes*”, in Trans on Control Systems Technology, Ferrara, 2000, pp.848-855.
- 9 L. A. Aguirre, Introdução à Identificação de Sistemas – Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais, Belo Horizonte, MG: Editora UFMG, 2000.
- 10 T. Söderström, H. Fan, B. Carlsson, S. Bigi “*Least Square Parameter Estimation of Continuous-Time ARX Model from Discrete-Time Data*”, In Trans. on Automatic Control, 1997, pp. 659-673.
- 11 OPC Foundation “OLE for Process Control” Available: <http://www.opcfoundation.org>