

FERRAMENTA EDUCACIONAL BASEADA EM SOFTWARE PARA O ENSINO DE IDENTIFICAÇÃO DE SISTEMAS

Maísa Lauriane Ferreira dos Santos¹ - maisalfsantos@gmail.com

Flavio da Silva Vitorino Gomes^{1,2} - flavio@cear.ufpb.br

Lincoln Machado de Araújo¹ - machado.lincoln@gmail.com

Ademar Gonçalves da Costa Junior¹ - ademarcosta@ifpb.edu.br

¹ Instituto Federal de Educação, Ciência e Tecnologia da Paraíba (IFPB)

Laboratório de Instrumentação, Sistemas de Controle e Automação (LINSCA)

² Universidade Federal da Paraíba (UFPB)

Centro de Energias Alternativas e Renováveis (CEAR)

João Pessoa – Paraíba, Brasil

Resumo: *O uso de ferramentas pedagógicas baseadas em software para o auxílio na consolidação do conhecimento, tem se tornado fundamentais para que os alunos possam correlacionar os conteúdos teóricos apresentados em sala de aula, com a prática, contextualizando esse aprendizado por meio de gráficos e figuras oriundos de experimentos ou simulações. Este trabalho tem o propósito de apresentar os resultados do desenvolvimento de uma ferramenta de software para o ensino da identificação de sistemas, em específico técnicas de identificação por predição do erro, utilizando uma planta piloto. Este desenvolvimento permitirá que o entendimento desse conteúdo tenha uma maior efetividade para os alunos uma vez que essa ferramenta mostrará a teoria aplicada em um sistema dinâmico que apresenta elementos semelhantes aos encontrados em um ambiente industrial.*

Palavras-chave: *Ferramenta de software. Identificação de sistemas. Identificação por predição do erro. Python. Software educacional.*

1 INTRODUÇÃO

Uma das atividades da Engenharia consiste em obter modelos matemáticos que possam representar o comportamento dinâmico de sistemas dinâmicos. Para isso, existem duas áreas de estudo para obter tais modelos, que são a modelagem caixa branca (GARCIA, 2009) e as modelagens caixa preta e caixa cinza (LJUNG, 1999; COELHO; COELHO, 2004; AGUIRRE, 2007).

A modelagem caixa branca consiste no equacionamento dos fenômenos envolvidos em sistemas dinâmicos, como por exemplo, o uso das leis da física, onde nem sempre existe a viabilidade no procedimento de modelagem por falta de conhecimento e de tempo necessário para a realização. Na modelagem caixa preta e caixa cinza, a identificação de sistemas é uma alternativa a modelagem caixa branca, no qual pouco, ou nenhum, conhecimento prévio do sistema é necessário, onde a análise é baseada em dados de entrada e de saída de sistemas dinâmicos.

Os métodos de identificação de sistemas para obter modelos matemáticos podem ser classificados em três categorias: métodos por predição do erro (SODERSTROM; STOICA, 1989; LJUNG, 1999; AGUIRRE, 2007); métodos por subespaço (VAN OVERSCHEE; DE

MOOR, 1996; KATAYAMA, 2005); e métodos não paramétricos (GREBLICKI; PAWLAK, 2008; PINTELON; SCHOUKENS, 2012).

Visando tornar mais didáticos os conceitos das áreas de sistemas de controle e de modelagem de sistemas, diversas pesquisas foram realizadas nas últimas décadas. Alguns trabalhos recentes incluem ambientes de simulações computacionais para o ensino, desenvolvimento de *kits* didáticos, implementação de ambientes virtuais, práticas de laboratório, entre outros (GUZMÁN *et al* 2011; COSTA *et al.*, 2017; SANTOS; VILAR; COSTA JUNIOR, 2018; GOERGEN *et al*, 2018;). Alguns estudos na área realizam testes e validações em diversos tipos de plantas pilotos como, por exemplo, em processos químicos (ALVARADO, 2013; MANAF *et al*, 2016; ASSUNÇÃO *et al*, 2018)

Este trabalho tem como objetivo apresentar o resultado do desenvolvimento de uma ferramenta educacional baseada em *software* para o ensino/aprendizagem de identificação de modelos matemáticos utilizando métodos de identificação por predição de erro aplicado a uma planta piloto de instrumentação industrial no Instituto Federal de Educação, Ciência e Tecnologia da Paraíba (IFPB), campus João Pessoa. A aquisição dos dados é realizada por meio do protocolo OPC (*Open Platform Communications*), com o método dos mínimos quadrados não-recursivos sendo utilizado para a obtenção dos parâmetros dos modelos ARX (*AutoRegressive models with eXogenous variables*) e ARMAX (*AutoRegressive Moving Average with eXogenous*) com o algoritmo desenvolvido em Python.

O artigo está dividido dessa forma: na seção 2 são apresentados, de forma sucinta, a fundamentação teórica básica utilizada; na seção 3 é apresentada a metodologia empregada no trabalho, descrevendo a planta didática utilizada e o procedimento adotado para a identificação de modelos matemáticos; nas seções 4 e 5 são apresentados os resultados obtidos e as considerações finais do trabalho, respectivamente.

2 FUNDAMENTAÇÃO TEÓRICA

Um modelo discreto linear invariante no tempo, que relaciona a saída de um sistema dinâmico, $y(k)$, com o sinal de entrada, $u(k)$, sendo $v(k)$ um ruído branco gaussiano, com média zero e variância unitária, pode ser escrito como (LJUNG, 1999):

$$y(k) = H(q)u(k) + G(q)v(k) \quad (1)$$

com $H(q)$ e $G(q)$ representando as funções de transferência do sistema e do ruído, respectivamente. A Equação (1) pode ser reescrita como um modelo generalizado linear para sistemas monovariáveis:

$$A(q)y(k) = \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}v(k) \quad (2)$$

sendo: q^{-1} o operador de atraso, de forma que $y(k)q^{-1} = y(k-1)$; e $A(q), B(q), C(q), D(q)$ e $F(q)$, os polinômios de ordem variada. De acordo com a existência desses polinômios, os modelos SISO são classificados conforme a estrutura do modelo, como por exemplo, a estrutura ARX ($A(q)$ e $B(q)$ presentes) e a estrutura ARMAX (os polinômios $A(q), B(q)$ e $C(q)$ presentes).

Segundo Coelho (2007), a seleção adequada das ordens dos polinômios da Equação (2) conduz ao melhor modelo matemático para a classe de modelos paramétricos, testados para um determinado sistema dinâmico. A qualidade dos modelos, relativa a um conjunto de medidas, deve ser obtida para cada aplicação particular, na etapa de validação. Também deve-

se optar pela simplicidade e precisão para a predição do comportamento observado a partir de determinados sinais de entrada, ou pelo uso de critérios de informação, entre outros métodos.

2.1 Estimação dos parâmetros

Um dos objetivos da estimação de parâmetros de um modelo matemático é encontrar um conjunto de coeficientes de uma estrutura de modelo escolhida, que permita descrever o comportamento dinâmico do sistema, a partir de entradas e de saídas passadas. Em geral, assume-se que as medições da entrada, $u(k)$, e da saída, $y(k)$, foram realizadas durante N instantes de amostragem. Desse modo, um conjunto de dados de entrada $\{u(1), \dots, u(N)\}$ e de saída $\{y(1), \dots, y(N)\}$ são disponibilizados.

A identificação paramétrica consiste na elaboração de modelos matemáticos para sistemas dinâmicos, com base nas variáveis observadas do sistema, de acordo com algum critério predefinido. A análise dessa identificação baseia-se em um modelo de regressão linear dado por (AGUIRRE, 2007):

$$y(k) = \varphi^T(k-1)\hat{\theta} + e(k) \quad (3)$$

com $\varphi(k-1)$ sendo o vetor de regressores até o instante $k-1$, com $(\cdot)^T$, o vetor transposto; $\hat{\theta}$, o vetor de parâmetros estimado; $e(k)$, o erro de predição, e $y(k)$, a saída do sistema dinâmico.

O problema de minimização do erro de predição por meio de uma função custo, possibilita a estimação do vetor de parâmetros pelo procedimento dos mínimos quadrados, ilustrado na Equação 4, e baseado no procedimento descrito em Aguirre (2007):

$$\hat{\theta} = [\varphi^T \varphi]^{-1} \varphi^T y \quad (4)$$

Segundo Coelho (2007), o objetivo é determinar um modelo paramétrico que descreva o comportamento dinâmico do sistema, com uma estrutura simples e precisa, que se ajuste às medidas com base no erro entre a saída real e a do modelo, no universo das observações dos dados do sistema. O modelo paramétrico caracterizado pela Equação (3) não só se direciona para equações de diferenças lineares, mas também para os algoritmos de estimação recursivos adaptados à implementação, por meio de algoritmos computacionais.

2.2 Validação do modelo matemático

Para validar um modelo é necessário verificar o resultado que ele consegue produzir para um conjunto de dados diferente do que foi utilizado para a estimação dos parâmetros do modelo. Um dos métodos de validação utilizados, é o índice MRSE (*Mean Relative Squared Error*) ilustrado na Equação 4.

$$MRSE = \left(1 - \sqrt{\frac{\sum_{k=1}^N (y(k) - \hat{y}(k))^2}{\sum_{k=1}^N (y(k))^2}} \right) \times 100\% \quad (5)$$

onde $y(k)$ é a saída real do sistema, e o $\hat{y}(k)$ é a saída estimada pelo modelo.

2.3 Protocolo de comunicação OPC

O protocolo digital de comunicação OPC (*Open Platform Communications*) é um padrão de interoperabilidade para a troca segura e confiável de dados no espaço da automação

industrial. O OPC independe da plataforma e garante o fluxo contínuo de informações entre dispositivos de diversos fornecedores.

O OPC constitui-se de um conjunto comum de interfaces, métodos e propriedades de comunicação, agregados dentro de uma especificação padronizada e aberta ao acesso público. A comunicação é realizada por meio de um arquitetura cliente-servidor, com o servidor OPC sendo a fonte de dados, e qualquer aplicativo cliente podendo acessá-lo para leitura e escrita da variável oferecida pelo servidor (GONZÁLEZ-ACEVEDO; VILLAMIZAR-GALVIS, 2019).

3 METODOLOGIA

Neste artigo, uma planta piloto de instrumentação industrial, modelo DLB CP003-HT da De Lorenzo foi utilizada. Essa planta piloto, ilustrada na Figura 1 possui um PLC da Siemens S7-1200, dois tanques com capacidade de 110 e 90 litros cada, duas válvulas pneumáticas, aquecedor elétrico, transmissores indicadores da Siemens para variáveis de pressão, nível e vazão, sensor de temperatura PT 100, bomba hidráulica entre outros componentes.

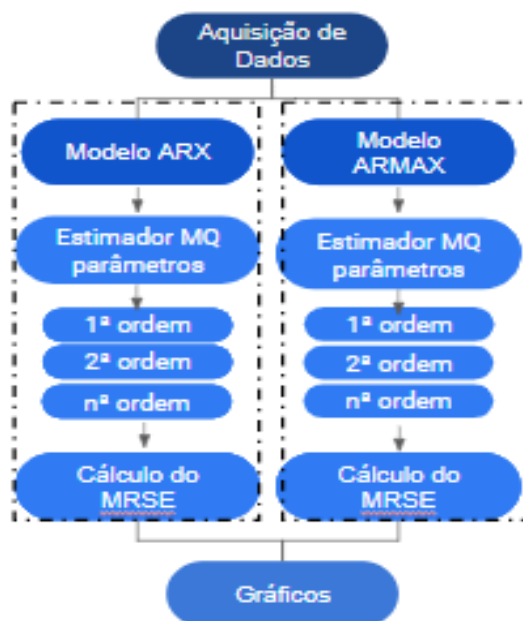
Figura 1 – Planta piloto de instrumentação industrial DBL CP003-HT.



Fonte: Acervo pessoal

A malha de nível da planta piloto foi escolhida para ser objeto de estudo e aplicação. Inicialmente, a configuração e calibração de todos os sensores e atuadores na planta, além da configuração de todas as *tags* no sistema supervisório (*Indusoft*) foram realizadas permitindo que o sistema dinâmico estivesse apto a receber os comandos advindos do algoritmo de estimação paramétrica utilizado. O algoritmo foi desenvolvido em Python para atuar como uma ferramenta de identificação por predição do erro, onde seu funcionamento é ilustrado pelo fluxograma da Figura 2.

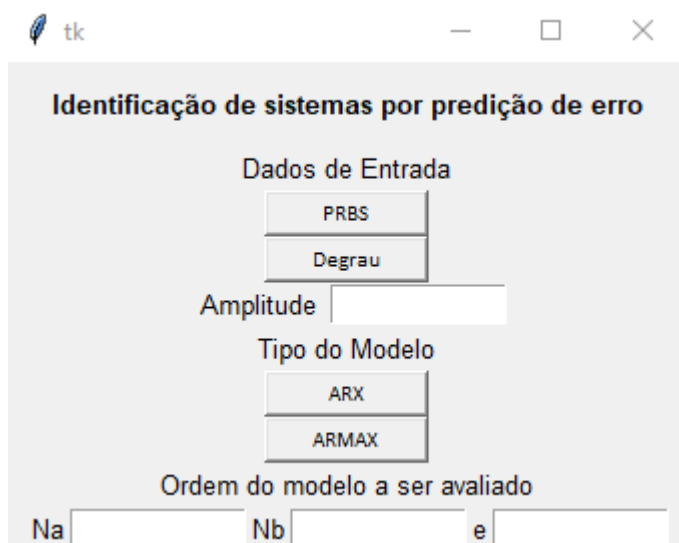
Figura 2 – Diagrama de blocos do algoritmo.



Fonte: Autoria própria.

Inicialmente, o usuário escolhe o tipo do sinal de entrada a ser aplicado ao sistema dinâmico. Dois tipos de sinais de entrada estão disponíveis para a identificação de sistemas, que é o sinal do tipo degrau e o PRBS (*Pseudo Random Binary Sequence*), além da escolha do valor da amplitude desejada. A próxima etapa é a escolha do modelo linear (ARX ou ARMAX) e a ordem a serem avaliadas. Nesta etapa, a biblioteca *TKinter* do *Python* foi utilizada, com a Figura 3 ilustrando essa parte da interface. Para uma avaliação quantitativa da qualidade do modelo obtido por meio das técnicas de identificação de sistemas por predição do erro, o índice MRSE é utilizado. Após a aquisição dos dados, os parâmetros dos modelos matemáticos são ilustrados para o usuário, bem com o sinais de saída experimental e identificado.

Figura 3 – Interface para entrada de dados desenvolvido em *TKinter* do *Python*.

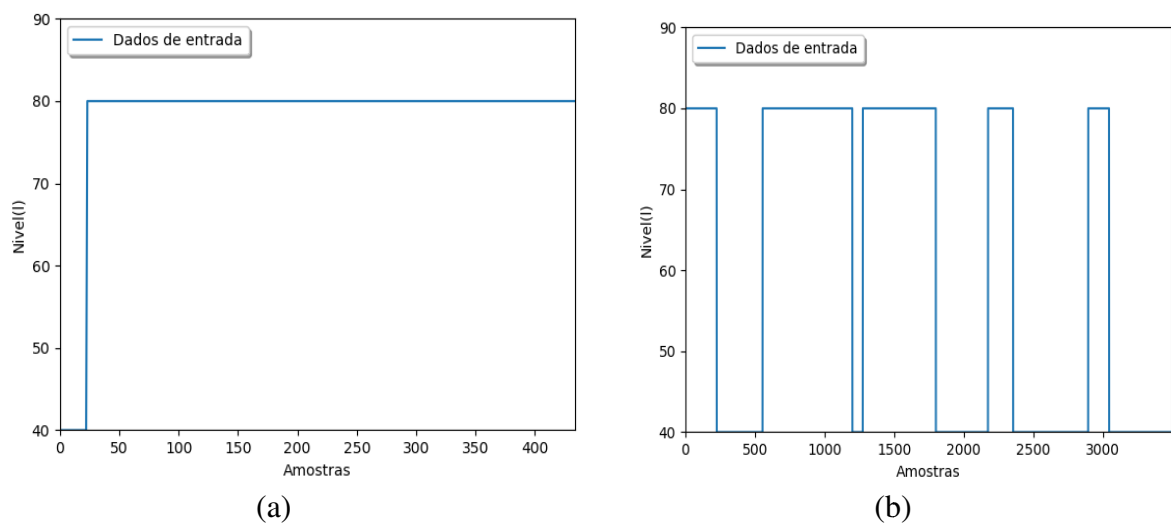


Fonte: Autoria própria.

4 RESULTADOS

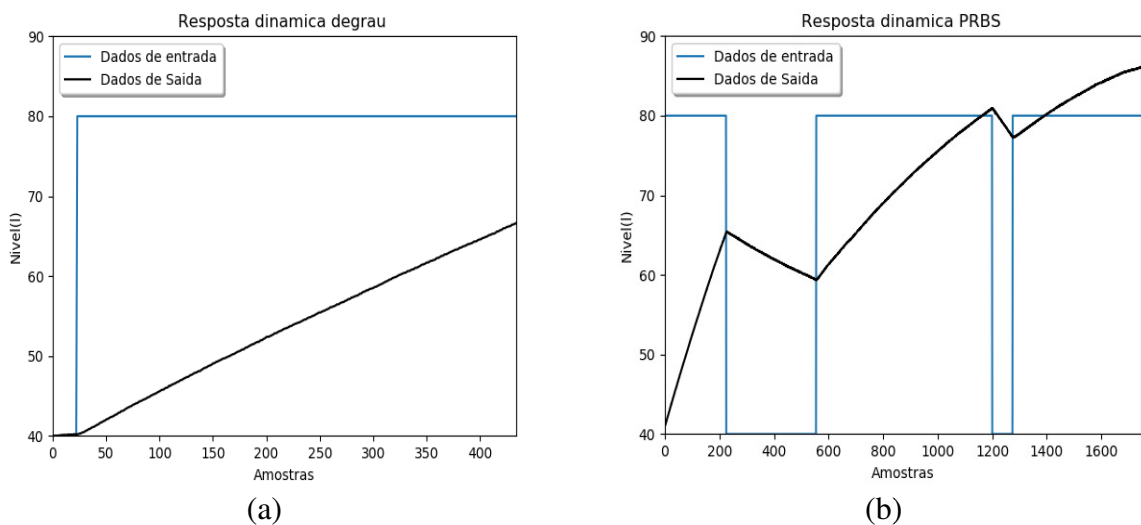
Nesta seção, os resultados do trabalho são apresentados. Um sinal do tipo degrau e um sinal PRBS, ilustrados na Figura 4, são escolhidos pelo usuário e aplicados como estudo de caso desse artigo, com variação de amplitude de 20 litros, que é a região de operação utilizada para o modelo a ser identificado. Os dados de saída, que representam o comportamento dinâmico em resposta aos sinais de entrada aplicados ao sistema, são adquiridos, sendo ilustrados na Figura 5.

Figura 4 – Sinais de excitação de entrada do tipo degrau (a) e PRBS (b).



Fonte: Dados do experimento.

Figura 5 – Resposta dinâmica do sistema ao sinal de excitação aplicado. (a) Resposta ao sinal do tipo degrau, (b) resposta ao sinal PRBS.



Fonte: Dados do experimento.

Os dados adquiridos são submetidos a uma análise para os modelos ARX e ARMAX para diversas ordens, onde o índice MRSE é calculado. Os valores dos índices MRSE estão ilustrados nas Tabelas 1 e 2, para os modelos ARX e ARMAX, respectivamente.

Tabela 1 – Resultado do índice MRSE do modelo ARX para entrada do sinal do tipo degrau e PRBS.

Ordem do modelo	MRSE Degrau	MRSE PRBS
1	95,18%	71,1%
5	95,8%	72,05%
10	95,84%	78,30%
20	97,2%	82,12%

Fonte: Dados do experimento.

Tabela 2 – Resultado do índice MRSE do modelo ARMAX para entrada do sinal do tipo degrau e PRBS.

Ordem do modelo	MRSE Degrau	MRSE PRBS
1	86,56%	70,23%
5	87,08%	71,42%
10	88,08%	80,06%
20	91,01%	81,02%

Fonte: Dados do experimento.

Na Figura 6 é apresentado o resultado da identificação do sistema utilizando o modelo ARX de primeira ordem com o algoritmo de estimação dos mínimos quadrados, que por parcimônia foi a ordem escolhida. Os parâmetros encontrados como resultado para o PRBS e o sinal do tipo degrau são apresentados nas Equações 6 e 7, respectivamente. O valor do índice de validação MRSE para o modelo de primeira ordem foi de 95,18% para o degrau e 71,1% para o PRBS, conforme indicado na Tabela 1.

$$y(k) = -0.998 * y(k - 1) + 0.002 * u(k - 1) \quad (6)$$


$$y(k) = -0.999 * y(k - 1) + 0.0012 * u(k - 1) \quad (7)$$

Na Figura 7 são ilustrados os resultados da identificação do sistema utilizando o modelo ARMAX de primeira ordem escolhida, também por parcimônia, com o algoritmo de estimação dos mínimos quadrados. Os parâmetros encontrados como resultado para os sinais do tipo degrau e PRBS podem ser visualizados nas Equações 8 e 9, respectivamente. O valor do índice de validação MRSE foi de 86,56% para o sinal do tipo degrau e 70,23% para o sinal PRBS, indicados na Tabela 2.

$$y(k) = -0.998 * y(k - 1) + 0.002 * u(k - 1) - 0.001 * e(k - 1) \quad (8)$$

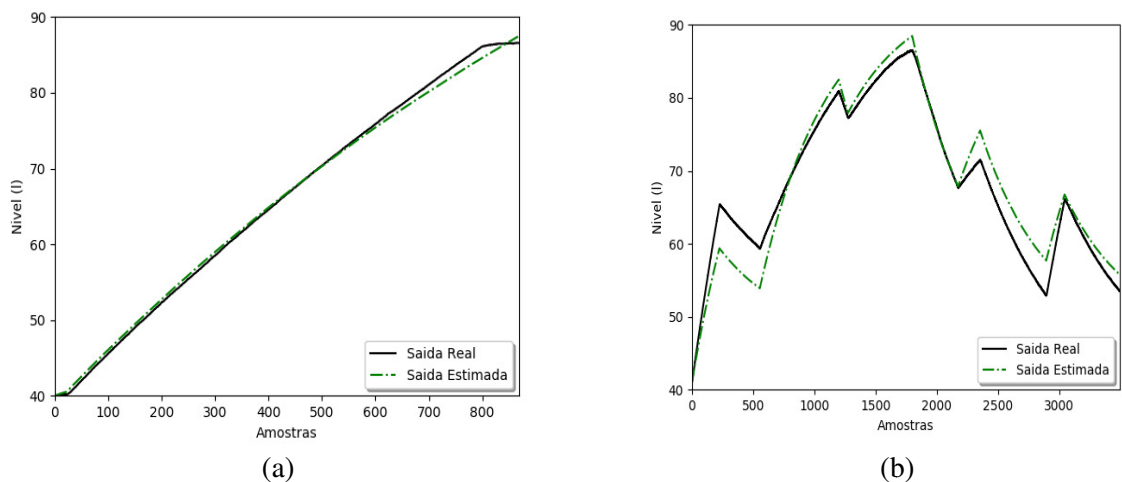
$$y(k) = -0.999 * y(k - 1) + 0.001 * u(k - 1) - 0.003 * e(k - 1) \quad (9)$$

Figura 6 – Modelo ARX primeira ordem. (a) Sinal do tipo degrau e (b) sinal PRBS.



Fonte: Dados do experimento.

Figura 7 – Modelo ARMAX de primeira ordem. (a) Sinal do tipo degrau e (b) sinal PRBS.



Fonte: Dados do experimento.

Estes resultados indicam que os modelos matemáticos obtidos são satisfatórios para que possam representar o comportamento dinâmico do sistema na faixa de operação escolhida. O modelo de primeira ordem é representado nesta seção e o escolhido no caso deste ser utilizado para o uso no projeto de controladores baseados em modelos.

5 CONCLUSÃO

A identificação de sistemas é uma técnica alternativa ao modelamento matemático que permite o aluno obter modelos matemáticos baseados em dados experimentais, sem a necessidade de desenvolver modelos matemático baseados nas equações fenomenológicas,

muitas vezes, complexos. A ferramenta de *software* desenvolvida permite que o estudante possa avaliar o uso dos mínimos quadrados, que é a base da identificação por predição do erro, utilizando modelos ARX e ARMAX e analisando-os por meio de gráficos e índices estatísticos.

A ferramenta de *software* desenvolvida será apresentada e avaliada pelos alunos de disciplinas da área de sistemas de controle, bem como, no futuro, disponibilizada de forma *online* para que os interessados possam baixá-la e utilizá-la, independente de qual sistema dinâmico esteja em uso. Os modelos matemáticos obtidos serão usados para o projeto de diversos tipos de controladores a serem aplicados na planta piloto existente, que é a próxima etapa do projeto.

Agradecimentos

Os autores agradecem o apoio técnico e financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e ao Instituto Federal de Educação, Ciência e Tecnologia da Paraíba (IFPB) pela infraestrutura disponibilizada.

REFERÊNCIAS

- AGUIRRE, L. A. Introdução à identificação de sistemas: técnicas lineares e não-lineares aplicadas a sistemas reais, 3ª edição. Belo Horizonte (Brasil): UFMG, 2007.
- ALVARADO, C. S. M. Identificação e controle preditivo de uma planta-piloto de neutralização de pH. 187 p. il. Dissertação (Mestrado em Engenharia de Sistemas). Escola Politécnica da Universidade de São Paulo, 2013.
- ASSUNÇÃO, M. L. M. *et al.* Desenvolvimento de sistema de supervisão e controle de uma planta de produção de cachaça tradicional: inovação e multidisciplinaridade na abordagem de identificação e controle de processos. *Revista Principia*, n. 39, p. 101-112, 2018.
- COELHO, A. A. R. Algoritmos para estimação paramétrica de sistemas lineares. In: AGUIRRE, L. A. (org.). *Enciclopédia de Automática*, v. 3. São Paulo: Blucher, 2007.
- COELHO, A. A. R.; COELHO, L. S. Identificação de sistemas dinâmicos lineares. Florianópolis (Brasil): Ed. UFSC, 2004.
- COSTA, T. A. *et al.* Identificação de parâmetros de um circuito RC de primeira ordem por mínimos quadrados não recursivos como forma de abordagem educacional. In: XLV Congresso Brasileiro de Educação em Engenharia (COBENGE 2017), Joinville - SC, Anais... 2017
- GARCIA, C. Modelagem e simulação de processos industriais e de sistemas eletromecânicos. São Paulo: Ed. USP, 2009.
- GOERGEN, R. *et al.* Cinemática direta e inversa de robôs industriais: metodologia de ensino em modelagem matemática para o caso de um robô antropomórfico. In: XLV Congresso Brasileiro de Educação em Engenharia (COBENGE 2017), Joinville - SC, Anais... 2017.
- GONZÁLEZ-ACEVEDO, G.; VILLAMIZAR-GALVIS, O. G. Implementación de un sistema de control para regular la velocidad y posición de motores industriales utilizando el protocolo de comunicación OPC. *Revista UIS Ingenierías*, v. 18, n. 2, p. 147-158, 2019.
- GREBLICKI, W.; PAWLAK, M. *Nonparametric system identification*. New York: Cambridge University Press, 2008.
- GUZMÁN, J. *et al.* Entornos de experimentación para la enseñanza de conceptos básicos de modelado y control. *Revista Iberoamericana de Automática e Informática Industrial RIAI*, v. 7, n. 1, p. 10-22, 2010.

KATAYAMA, T. Subspace methods for system identification: a realization approach. Germany: Springer, 2005.

LJUNG, L. System identification: theory for the user. Englewood Cliffs (United States): Prentice-Hall, 1999.

MALDONADO, J. L. B. *et al.* Infraestrutura da tecnologia da informação do Macrolaboratório de controle automático da UNL para um ambiente virtual de aprendizagem. In: XLV Congresso Brasileiro de Educação em Engenharia (COBENGE 2017), Joinville (Brasil), Anais... 2017

MANAF, N. A. *et al.* Dynamic modelling, identification and preliminary control analysis of an amine-based post-combustion CO₂ capture pilot plant. Journal of Cleaner Production, v. 113, p. 635-653, 2016.

PINTELO, R.; SCHOUKENS, J. System identification: a frequency domain approach. Wiley, 2012.

SANTOS, J. A. S.; VILAR S. R., COSTA JUNIOR. A. G. Desenvolvimento de uma ferramenta educacional para auxiliar no ensino e aprendizagem de identificação de sistemas dinâmicos. In: XLVI Congresso Brasileiro de Educação em Engenharia, 2018, Salvador (Brasil). Anais.... 2018.

SÖDERSTROM, T.; STOICA, P. System identification. Englewood Cliffs: Prentice Hall, 1989.

VAN OVERSCHEE, P.; DE MOOR, B. Subspace identification for linear system: theory, implementation, applications. Dordrecht (Netherlands): Kluwer, 1996.

SOFTWARE-BASED EDUCATIONAL TOOL FOR SYSTEM IDENTIFICATION TEACHING

Abstract: *The use of software-based pedagogical tools to assist in the consolidation of knowledge has become fundamental so that students can correlate the theoretical contents presented in the classroom with the practice, contextualizing this learning through graphs and figures from experiments or simulations. This paper aims to present the results of the development of an educational tool for systems identification teaching, specifically prediction error methods (PEM), using a pilot plant. This development will allow the understanding of this content to have greater effectiveness for the students since this tool will show the applied theory in a dynamical system that presents elements similar to those found in an industrial environment.*

Key-words: *Educational software. Prediction error method. Python. Software tool. System identification.*