



IDENTIFICAÇÃO DE SISTEMA NÃO LINEAR EM TEMPO REAL ATRAVÉS DE REDES NEURAS ARTIFICIAIS

¹ Filipe Sousa Pacheco de Almeida (CIMATEC) – filipespacheco@hotmail.com; ² Maico Camerino dos Santos (CIMATEC) – maicocamerino@gmail.com; ³ Emanuel Benício de Almeida Cajueiro (CIMATEC) – emanuel.cajueiro@fieb.org.br

Resumo: Este trabalho apresenta o desenvolvimento de um método para identificação de sistemas em tempo real usando Redes Neurais Artificiais (RNA), em que a rede é atualizada à medida que o processo estudado se modifica. O desenvolvimento do trabalho conta com a construção de um modelo real para comparação dos resultados com uma abordagem analítica e a apresentação de uma alternativa para ser utilizada quando a abordagem analítica se tornar inviável, sendo esta o principal foco deste artigo. A construção do sistema real permitiu validação da abordagem analítica, tanto quanto a identificação pela RNA. Apesar da RNA ter se mostrado capaz de aprender o sistema em tempo real, esta se mostrou incapaz em generalizar o sistema.

Palavras-Chaves: Identificação de Sistemas Dinâmicos; Modelagem em tempo real; Redes Neurais Artificiais, Sistema de Tanques.

IDENTIFICATION OF NON LINEAR SYSTEM IN REAL TIME BASED ON ARTIFICIAL NEURAL NETWORKS

Abstract: This work presents the development of a method for the identification of real-time systems using Artificial Neural Networks (ANN), where the network is modified while the studied process change. The development of the work had have the construction of a real model for the comparison of results with an analytical approach and a presentation of an alternative, when the analytical version is not feasible, thus this is the main focus of the article. The construction of the real system has served to validate the analytical approach and the identification of ANN. In spite of, ANN was able to learn the system in real time, it was not able to generalize the system.

Keywords: Identification of Dynamic Systems; Real-time modeling; Artificial Neural Networks, Tank System.



1. INTRODUÇÃO

Com o avanço das ferramentas computacionais e das demandas por processos industriais mais otimizados e melhores controlados, a obtenção de modelos matemáticos de plantas industriais se tornou uma etapa importante para otimização e simulação destes processos. Por isso, desde o final da segunda guerra mundial os computadores tornaram-se aliados na identificação de sistemas (modelagem) e simulação de sistemas dinâmicos [1].

Equações fenomenológicas (modelos caixa-branca) muitas vezes são difíceis de serem obtidas. Isto, porque, para obtê-las faz-se necessário conhecer todos os fenômenos que descrevem o comportamento de um sistema. Logo, esta abordagem de modelagem pode consumir uma grande quantidade de tempo e dinheiro, os quais nem sempre se tem disponível [2], [3]. Neste caso, uma alternativa interessante para modelagem caixa-branca é a identificação caixa-preta de sistemas dinâmicos [3].

O princípio básico da identificação de sistemas é a obtenção de modelos matemáticos capazes de representar as características estáticas e dinâmicas de um sistema real, baseados nos dados experimentais [3]. Embora em alguns casos as aproximações lineares sejam suficientes para representar aplicações práticas, os sistemas dinâmicos encontrados no mundo real são, em última análise, não-lineares. Para sistemas que operam em larga faixa de operação ou sistemas altamente não-lineares, modelos lineares não são suficientes [3]. Em [4] é possível verificar a utilização de uma rede neural para identificação de sistemas dinâmicos.

Destaca-se como contribuição deste trabalho o desenvolvimento e treinamento de uma (RNA) em tempo real que tem a habilidade de aprender as características do sistema observado, que no caso é o comportamento de nível em um tanque cilíndrico deitado com escoamento pelo efeito da gravidade sem fluxo de entrada no tanque. Paralelamente foi realizada a modelagem caixa-branca do sistema para comparação com os dados reais.

2. METODOLOGIA

A metodologia usada no desenvolvimento do trabalho é descrita nas subseções 2.1 e 2.2.

2.1 Aparato experimental

Foi construído um protótipo de um sistema de tanques em escala, conforme Figura 1. O objetivo deste protótipo é adquirir os sinais necessários para a identificação do sistema dinâmico. Apesar dos métodos de identificação serem bastante difundidos, lidar com sistemas reais ainda é desafiador; quer seja pelas simplificações que são realizadas para a simulação do sistema ou pelo esforço no pré-processamento dos sinais que serão adquiridos por meio dos sensores.

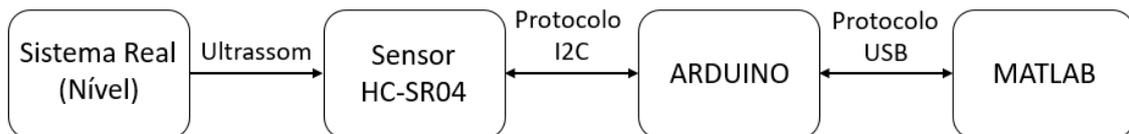


Figura 1. Foto do sistema desenvolvido.



A aquisição de dados foi realizada através de um sensor ultrassônico (HC-SR04). A Figura 2 demonstra o fluxo da informação até a chegada do algoritmo de identificação do sistema. O tempo de amostragem escolhido para tomada dos dados foi de 1 segundo.

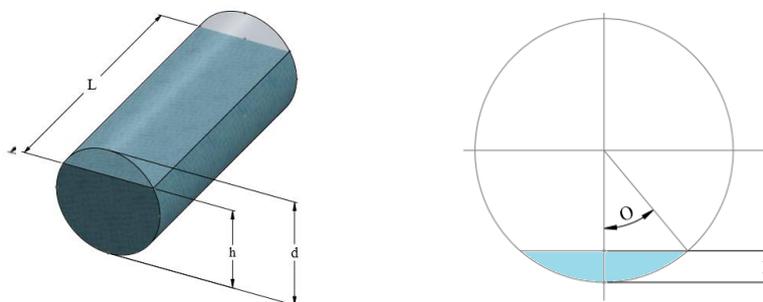
Figura 2. Sistema de aquisição de nível.



O sistema estudado se trata de um tanque cilíndrico, horizontal, e sua modelagem pode ser realizada pelo método do Cálculo Newtoniano ou pela Geometria Euclidiana, conforme é demonstrado em [5].

A Figura 3 ilustra o tanque com suas devidas dimensões, em que d corresponde ao diâmetro do cilindro, L ao comprimento do cilindro e h à altura de líquido no cilindro, também é possível observar que o volume de líquido no interior do tanque varia de acordo com a altura.

Figura 3. Ilustração gráfica do tanque cilíndrico horizontal.



Utilizando-se do cálculo diferencial é possível encontrar a área em azul na Figura 3, através da seguinte integral.



$$A = 2 \int_0^h x dy \quad (1)$$

Em que dy pode ser reescrito como:

$$dy = r \sin(\theta) d\theta \quad (2)$$

Portanto, alterando-se os limites de integração e substituindo a equação (3) na equação (1), tem-se que:

$$A = 2 \int_0^\theta r^2 \sin^2(\theta) d\theta \quad (3)$$

Resolvendo-se a integral acima chega-se à:

$$A = r^2 \left(\cos^{-1} \left(\frac{r-h}{r} \right) - \left(\frac{r-h}{r} \right) \sqrt{1 - \left(\frac{r-h}{r} \right)^2} \right) \quad (4)$$

A equação (4) pode ser denominada como equação constitutiva do sistema, contudo para se criar uma simulação do escoamento neste corpo é necessário que a partir desta equação constitutiva chegue-se a equação dinâmica do sistema. Para alcançar tal equação é necessário realizar o balanço de massa deste sistema, portanto:

$$\frac{dm}{dt} = w_i(t) - w_o(t) \quad (5)$$

Em que, dm/dt corresponde a taxa de variação de massa em função do tempo e $w_i(t)$ e $w_o(t)$ as vazões mássicas de entrada e saída respectivamente. É possível relacionar a massa com o volume contido no tanque através da equação de densidade, logo:

$$m = \rho V \quad (6)$$

Em que, ρ representa a densidade do fluido contido no tanque e V representa o volume do corpo, substituindo a equação (6) na equação (5), tem-se que:

$$\rho \frac{dV}{dt} = w_i(t) - w_o(t) \quad (7)$$

Entretanto, como pode ser visto na equação (8) o volume não varia de maneira uniforme em relação ao crescimento da altura, portanto, realizando a regra da cadeia na equação (8) da altura com relação ao tempo e substituindo na equação (7) tem-se que:

$$\left[2r \sqrt{\frac{2hr-h^2}{r^2}} \right] L \frac{dh}{dt} = \frac{w_i(t)-w_o(t)}{\rho} \quad (8)$$

Rearranjando os termos da equação (8) e realizando a divisão na segunda parte da equação alcança-se os termos de F_i e F_o que representam a vazão volumétrica de entrada e saída do tanque, respectivamente, portanto:



$$\frac{dh}{dt} = \frac{1}{2r\sqrt{\frac{2hr-h^2}{r^2}}} \frac{F_i(t)-F_o(t)}{L} \quad (9)$$

Em algumas situações a vazão de saída é assumida como sendo linear em função apenas da altura do tanque, contudo, uma visão mais realista, esta vazão pode ser obtida quando a abertura da válvula de saída é fixa e é colocada na saída da linha, enquanto que a força condutora do fluido na válvula é dada pela queda de pressão:

$$\Delta P = P - P_a \quad (10)$$

Em que P e P_a representam a pressão no fundo do tanque e a pressão atmosférica ao qual o tanque está submetido respectivamente. Assumindo que a saída do tanque também está direcionada para atmosfera e a válvula é considerada ser um orifício, a equação de Bernoulli pode ser utilizada para alcançar a seguinte relação (SEBORG *apud* (Bird *et al.*) [6]):

$$F_o(t) = C_v \sqrt{\frac{\Delta P}{\rho}} \quad (11)$$

Em que C_v representa uma constante relacionada ao escoamento da válvula. Utilizando-se o princípio de Stevin da hidrostática na equação (11), chega-se à:

$$F_o(t) = C_v \sqrt{gh(t)} \quad (12)$$

Em um escoamento ideal a equação (12) representa a vazão do escoamento, contudo, em um sistema real é notório que existem imperfeições naturais aos sistemas que ajudam a reduzir a velocidade do escoamento, pode-se generalizar estes fatores a perda de carga. Este fator depende de várias variáveis, contudo o mesmo pode ser simplificado e linearizado, conforme [1]. Por isso um coeficiente linear deve ser inserido na equação (12), chega-se à:

$$F_o(t) = C_g C_v \sqrt{gh(t)} \quad (13)$$

Substituindo-se a equação (13) na equação que representa a resposta dinâmica do sistema (9), tem-se que:

$$\frac{dh}{dt} = \frac{1}{2r\sqrt{\frac{2hr-h^2}{r^2}}} \frac{F_i(t)-C_g C_v \sqrt{gh(t)}}{L} \quad (14)$$

A Equação (14) pode ser considerada a equação característica para este sistema, cuja entrada é representada por F_i . Durante a etapa de obtenção dos dados desconsiderou-se a entrada de fluido no sistema. Logo, a coleta de dados é realizada apenas sobre o efeito do campo gravitacional da terra que realiza o escoamento do fluido. Neste trabalho comparou-se as estimativas realizadas pela rede neural na identificação do sistema, com o resultado teórico promovido pela equação característica, juntamente com o resultado real obtido do próprio sistema físico.

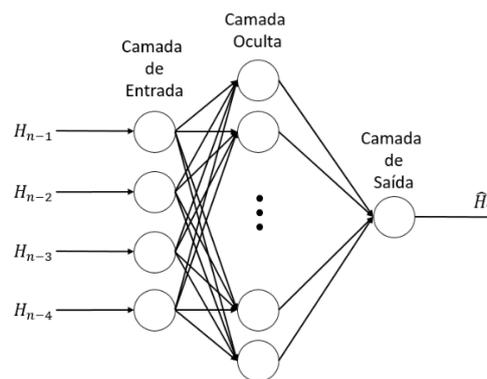


A arquitetura da RNA escolhida para aprender este sistema é do tipo *feedforward* com uma camada escondida. Na camada de entrada existem neurônios que correspondem aos quatro últimos instantes do sistema real. As entradas da rede são apresentadas pelo vetor X , sendo este composto por: X . A camada oculta possui 30 neurônios enquanto que na saída existe apenas um neurônio. Em que a saída representa a estimativa da altura no instante atual. Todos os neurônios da camada oculta e de saída possuem como função de ativação a função sigmoide, $\varphi(x) = \tanh(x)$. Sendo M_1 e M_2 as matrizes dos pesos sinápticos, a função matemática que representa a saída estimada da rede neural é apresentada por:

$$\hat{H}_n = \varphi(M_2 \times \varphi(M_1 \times [X])^T) \quad (15)$$

O algoritmo utilizado para o treinamento da rede foi o *Backpropagation (BP)*, como pode ser visto em [7], cujo resultado é uma generalização do algoritmo de [8]. A Figura 4 ilustra graficamente a RNA empregada neste trabalho.

Figura 4. Ilustração gráfica da RNA.



3. RESULTADOS E DISCUSSÃO

Através do sensor ultrassônico foi possível coletar os dados que estão representados na Figura 5(a). É possível notar que existe uma variação natural nos dados que tende a desaparecer a medida que o nível no interior do tanque diminui, isso se dá as possíveis oscilações causadas pelo escoamento do fluido em sua superfície que tendem a serem menor em níveis mais baixos onde o volume é menor. A Figura 5(b) representa a curva de escoamento do nível do tanque cilíndrico com a abordagem analítica alcançada através da simulação da equação (14). É possível observar que ambas as curvas possuem a mesma tendência evidenciando a factibilidade da abordagem analítica.

Na Figura 6(a), são mostrados os dados medidos do tanque (gráfico em azul) e a estimativa em tempo real da RNA (gráfico em vermelho). É possível notar que como os pesos sinápticos da RNA são iniciados de maneira aleatória, existe um erro que passa a decrescer ao passo que a RNA é treinada pelo algoritmo *Backpropagation*. Também é possível perceber que a rede também reproduz os ruídos advindos da fonte de aquisição de dados, o sensor.



Figura 5. Respostas do Sistema real e dos dados estimados.

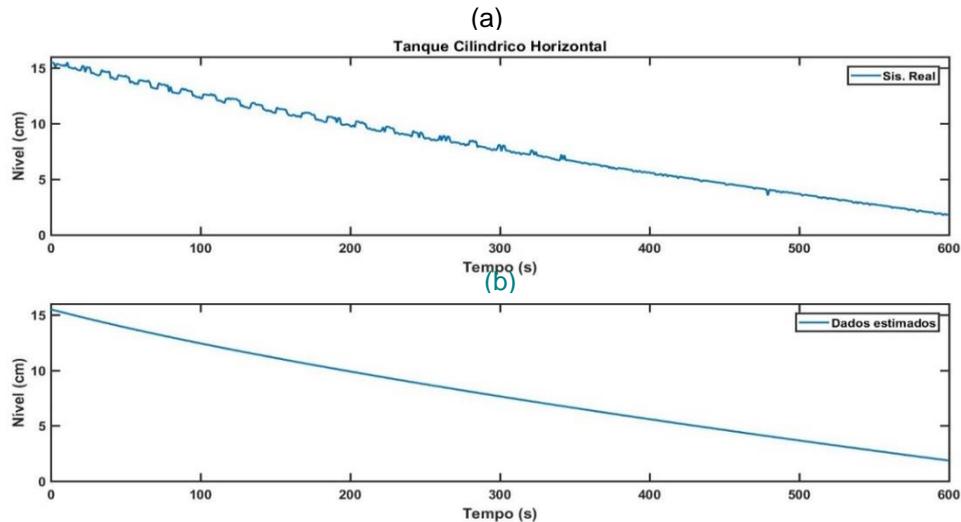
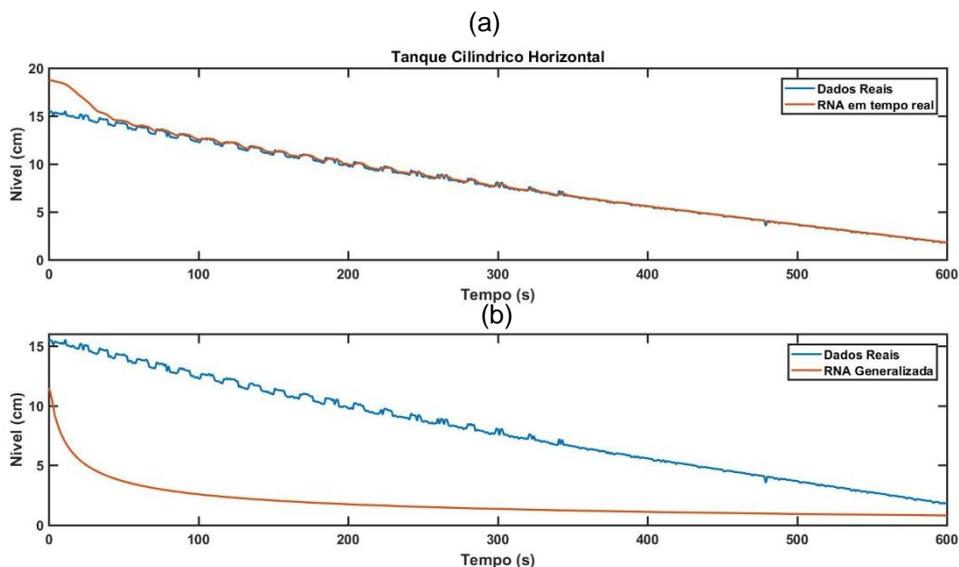


Figura 6. Ilustração gráfica do tanque cilíndrico horizontal.



Na Figura 6(b) demonstra-se a curva da queda do nível do tanque estimada pela RNA numa tentativa de generalização da mesma. Essa generalização foi realizada da seguinte maneira: após o último treinamento da RNA os pesos simpáticos são mantidos fixos (não existe mais treinamento) e então é apresentado a RNA os dados iniciais do nível do tanque. Ao produzir uma nova estimativa esta é realimentada em uma das entradas da RNA que então reutiliza os próprios dados estimados para produzir dados futuros.

Esta generalização resulta na curva em vermelho na parte inferior da figura acima. Nota-se que apesar de conseguir aprender o sistema em tempo real a RNA com aprendizado em tempo real, nesta abordagem, foi incapaz de generalizar o sistema a ela apresentado. O treinamento contínuo da rede pode contribuir para a



fraca generalização do sistema analisado o que pode ser uma deficiência ao utilizar este método para simulação de um sistema, entretanto, pode ser uma excelente ferramenta quando se deseja observar o comportamento do sistema alguns instantes a frente.

4. CONCLUSÃO

Após a análise dos resultados finais é possível afirmar que a RNA se mostra como uma alternativa viável para a modelagem de sistemas dinâmico em tempo real, ainda que exista não linearidades e ruídos intrínsecos à aquisição de dados de processos reais. Por outro lado, a RNA se mostrou deficiente durante a simulação com dados iniciais distantes dos últimos dados fornecidos para o treinamento. Tal deficiência pode estar ligada ao método de algoritmo escolhido para o treinamento ou ainda, a real necessidade de treinamento em tempo real pode contribuir para um problema clássico no treinamento de redes neurais quando existe um excesso de treinamento, também conhecido na literatura como *overfitting*. Esta abordagem alternativa pode ser útil para controladores baseados em modelo não lineares, desde que não as ações de controle implementadas pelo controlador não possuam grande variação em um curto espaço de tempo.

5. REFERÊNCIAS

- [1] GARCIA, C. **Modelagem e Simulação**. São Paulo: EdUSP, 2005.
- [2] LJUNG, L. Black-box models from input-output measurement, IEEE Instrumentation and Measurement, Technology Conference, Budapest, Hungary, May 21-23, (2001).
- [3] CAJUEIRO, E; KALID, R., SCHNITMAN, L. Inferindo Posição de Haste de Bombeio Mecânico a Partir de Corrente de Motor. X Congresso Brasileiro de Inteligência Computacional, CBIC, 2011.
- [4] O. NELLES, Nonlinear System Identification: From Classical Approaches to Neural Network and Fuzzy Models, Springer, (2001).
- [5] LIMA, M. P.; ZANETTE, R.; BAVARESCO, D.. **Determinação do volume do cilindro horizontal - Solução pertinente para um trabalho de formação básica**. III EIEMAT, 2012.
- [6] SEBORG, D. E.. **Process dynamics and control**. John Willey & Sons. 1ª Ed., 1995.
- [7] WERBOS, P.. **Beyond regression: New tools for prediction and analysis in the behavioral sciences**. Ph.D. Dissertation, Havard University, Cambrigde, MA – 1974.
- [8] WIDROW, B.; HOFF, M. E.. **Adaptative switching circuits**. IV IRE Western Electric Show and Convention Record. p. 96 – 104, 1960