



MODELAGEM DA DINÂMICA DE PRESSÃO E VAZÃO DE UMA PLANTA DIDÁTICA DE CONTROLE DE PROCESSOS NÃO LINEAR UTILIZANDO REDES NEURAIIS ARTIFICIAIS

Lorraine Marques Alves – lorraine_ma@hotmail.com

Gustavo Maia de Almeida – gmaia@ifes.edu.br

Wallas Gusmão Thomaz – wallas@ifes.edu.br

Instituto Federal do Espírito Santo, Unidade Serra, Coordenadoria de Automação Industrial.

Rodovia ES-010 – Km 6,5 - Manguinhos

29173087 – Serra – Espírito Santo

Resumo: A utilização de plantas piloto no ensino de engenharia é imprescindível para a fixação e demonstração dos conceitos aprendidos em sala de aula. Para as diversas aplicações como o controle de processos é importante determinar o modelo matemático do processo em questão. O objetivo deste trabalho é mostrar a determinação de um modelo matemático da dinâmica de pressão e vazão de uma planta didática não linear e multivariável através da utilização de redes neurais artificiais. Esta planta didática é utilizada no curso de engenharia de controle e automação do IFES – SERRA (ES). Redes neurais são algoritmos que tentam emular de uma forma muito simplificada a maneira como o cérebro humano processa determinadas informações e são baseadas em processadores elementares chamados neurônios. Neste trabalho foi avaliada a capacidade das redes neurais modelarem o processo descrito pela planta didática em questão.

Palavras-chave: Planta Didática Industrial, Modelagem, Redes neurais artificiais.

1. INTRODUÇÃO

No ensino de engenharia de Controle e Automação, a utilização de plantas didáticas com equipamentos de porte industrial é importante para proporcionar ao aluno um contato com a instrumentação usada em um processo industrial. Além disso, as Plantas didáticas também incentivam e proporcionam o desenvolvimento de trabalhos práticos de modelagem e de controle.

Dessa maneira, as instituições de ensino investem no desenvolvimento de plantas piloto com o objetivo de permitir ao aluno o contato com vários tipos de problemas de controle, desde os mais simples, chegando até aqueles de soluções mais complexas e também desenvolver algoritmos de controle estudados no meio acadêmico e testá-los num ambiente com características semelhantes ao industrial. Para o ensino e pesquisa em controle de processos as principais plantas didáticas utilizadas são as do tipo coluna de destilação e do tipo tanques acoplados. A planta do tipo coluna de destilação simula o equipamento mais importante utilizado no processo de destilação fracionada empregado largamente na indústria

Realização:



Organização:





química e petroquímica. Muitos processos industriais apresentam tanques interconectados para armazenagem de produtos líquidos, como por exemplo, o armazenamento de petróleo em refinarias. Essa estrutura é representada pela planta piloto do tipo tanques acoplados, utilizada em diversas instituições de ensino superior.

Através do modelo matemático da planta didática utilizada, pode-se calcular a resposta e descrever comportamento do processo de acordo com determinadas condições operacionais. Nesse trabalho, utiliza-se a análise experimental através da aplicação de redes neurais artificiais para a modelagem de uma planta didática não linear e multivariável. A utilização de redes neurais artificiais é justificada devido à dificuldade de se modelar tais processos, caracterizados por serem altamente complexos e não-lineares, visto que a forma como os problemas são modelados pela abordagem de redes neurais e o paralelismo natural inerente à sua arquitetura criam a possibilidade de um desempenho superior à dos modelos convencionais. Para o desenvolvimento do trabalho, é utilizado o software MATLAB desenvolvido pela Mathworks Company juntamente com a ferramenta Neural Networks Toolbox para o treinamento da rede.

2. REDES NEURAIS ARTIFICIAIS

Redes neurais são algoritmos que tentam emular de uma forma muito simplificada a maneira como o cérebro processa determinadas informações e são baseadas em processadores elementares chamados neurônios. Suas semelhanças com o cérebro humano baseiam-se em dois aspectos fundamentais (HAYKIN, 1999):

- Conhecimento é adquirido pela rede através de um processo de aprendizado e;
- A intensidade, ou força da conexão entre os neurônios, conhecida como pesos sinápticos são usadas para armazenar o conhecimento.

O processo de aprendizagem de uma rede neural é chamado de treinamento. O treinamento de uma rede consiste no ajuste dos pesos sinápticos de acordo com o algoritmo escolhido. A vantagem da aplicação de redes neurais na modelagem de um processo em relação às análises físico-matemáticas é a facilidade na obtenção do modelo e a possibilidade de se obter um modelo mais preciso. Tal poder computacional é obtido através da sua estrutura maciçamente paralelamente distribuída e da sua habilidade de aprender.

As unidades simples de processamento de informação de uma rede neural artificial são denominadas neurônios artificiais. Cada neurônio é formado por um conjunto de sinapses, um combinador linear e uma função de ativação. Cada sinapse ou elos de ligação é caracterizado por um peso, que representa o coeficiente de correlação entre os neurônios e pode assumir valores positivos ou negativos. O combinador linear soma os sinais de entrada ponderados pelas respectivas sinapses e a função de ativação restringe a amplitude da saída de um neurônio. A rede funciona portanto, através da disseminação de estímulos através de suas camadas, sendo que a matriz de pesos sinápticos vai modificando esses estímulos, gerando respostas diferentes para estímulos diferentes. O bias tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação se ele for positivo ou negativo, respectivamente. A Figura 1 ilustra o funcionamento de um neurônio que irá receber uma série de sinais de entrada, cada qual ativado com um determinado peso. Os sinais serão combinados através de uma função aditiva, que pode ser influenciada pelo bias introduzido no sistema. O resultado é



filtrado por uma função de ativação, que gera um sinal de saída. Esse sinal, por sua vez, servirá de estímulo para o próximo neurônio.

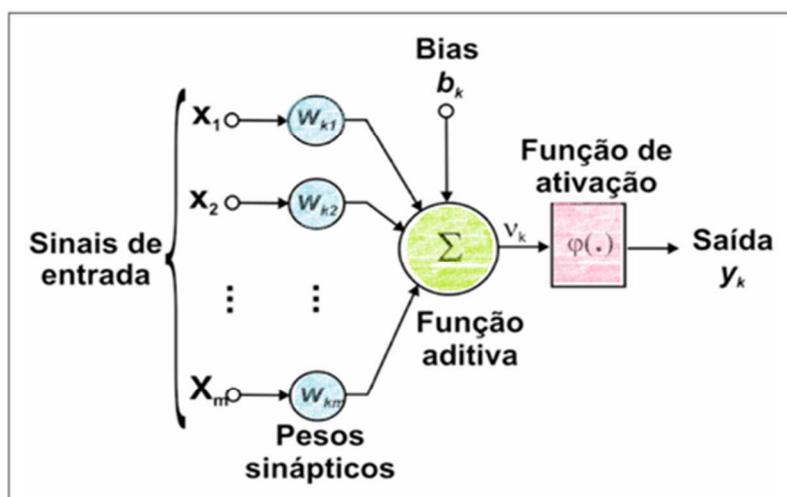


Figura 1 – Funcionamento de um neurônio

Os algoritmos de aprendizagem utilizados no projeto de redes neurais são estruturados. A maneira pela qual os neurônios estão estruturados em uma rede está intimamente ligada com o algoritmo de treinamento. Portanto é importante conhecer as arquiteturas de redes mais comuns utilizadas no projeto de redes neurais artificiais (HAYKIN, 1999). Em geral podemos identificar dois grupos de arquiteturas fundamentalmente diferentes: Feed-forward Networks (Redes alimentadas adiante) e Recurrent Networks (Redes recorrentes). Em redes do tipo feed-forward os dados de entrada são ponderados pelos pesos sinápticos e transmitidos para a saída dos neurônios de maneira unidirecional, ou seja, não há realimentação dos dados. Podemos classificar as redes neurais artificiais em subgrupos denominados feed-forward com camada única, redes feed-forward com múltiplas camadas e redes recorrentes.

Redes alimentadas adiante com camada única: na forma mais simples de uma rede em camadas, temos uma camada de entrada de nós de fonte que se projeta sobre uma camada de saída de neurônios, mas não vice-versa.

Redes alimentadas diretamente com múltiplas camadas: se distingue pela presença de uma ou mais camadas ocultas, cujos nós computacionais são chamados de neurônios ocultos, cuja função é intervir entre a entrada externa e a saída da rede de uma maneira útil. Ao adicionar camadas ocultas, a rede se torna capaz de extrair estatísticas de ordem elevada.

Recurrent Networks: a rede neural recorrente diferencia-se da rede neural alimentada adiante (feed-forward) por ter pelo menos um laço de realimentação. Pode possuir camadas únicas ou múltiplas.

A Figura 2 ilustra respectivamente redes do tipo feed-forward com camada única, redes feed-forward com múltiplas camadas e redes recorrentes respectivamente.

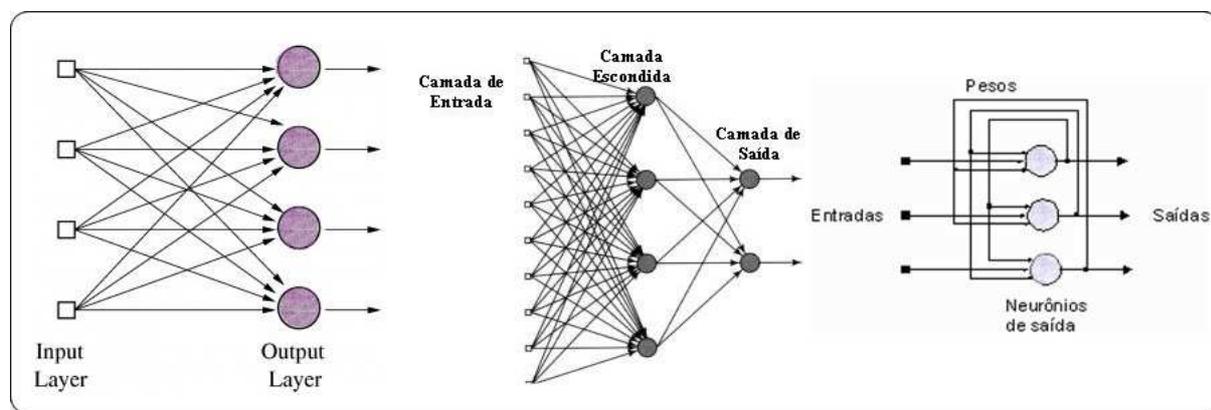


Figura 2 – Arquiteturas de redes neurais artificiais

2.1 Processos de aprendizagem

A aprendizagem está associada à capacidade de reproduzir um evento observado anteriormente. Em redes neurais utilizamos o termo aprendizagem para descrever o processo pelo qual os pesos sinápticos são ajustados através de um processo de estimulação do ambiente onde a rede se encontra. Dessa forma, a cada modificação dos parâmetros a rede responde ao ambiente de uma maneira diferente. O conjunto de regras utilizadas no processo de aprendizagem é denominada algoritmo de treinamento. Os algoritmos de treinamento se distinguem entre si pela maneira com que é realizado o ajuste dos pesos sinápticos e são influenciados pela arquitetura da rede e pela sua maneira de interagir com o ambiente. Considerando a interação da rede neural com o ambiente encontramos dois tipos de aprendizagem: supervisionada e não supervisionada. Abaixo será abordada uma pequena introdução ao processo de aprendizagem supervisionado que é o utilizado neste trabalho.

Aprendizagem supervisionada:

Também denominada aprendizagem com um professor. Nesse tipo de aprendizagem o professor é aquele que possui um conhecimento do ambiente na qual a rede está inserida, este conhecimento pode ser representado por um conjunto de dados de entrada-saída. No processo de treinamento o professor é capaz de fornecer a rede neural os dados de saída desejados para determinado vetor de entradas do sistema. Dessa maneira os pesos sinápticos da rede são ajustados objetivando a minimização do erro entre a resposta de saída da rede e a resposta esperada. Esse procedimento é realizado iterativamente até que a rede seja capaz de emular o professor e lidar com o ambiente inteiramente por si mesma.

A Figura 3 ilustra as etapas do processo de aprendizagem supervisionada, na qual a rede é submetida a um vetor de dados entrada-saída.

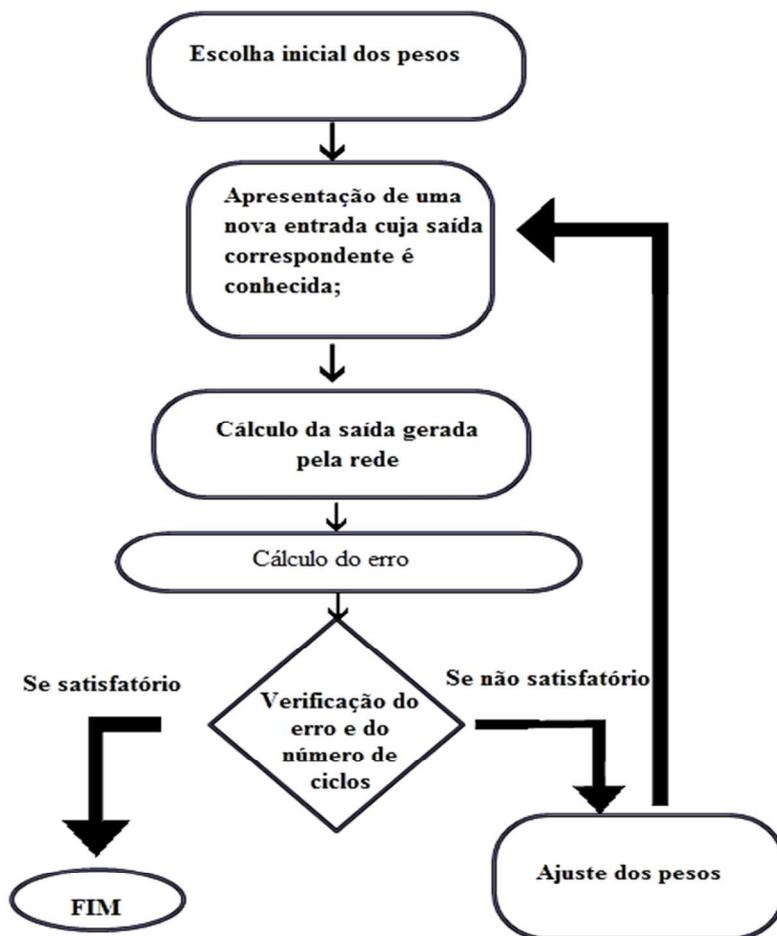


Figura 3 – Etapas da aprendizagem supervisionada

2.2 Perceptrons de Múltiplas Camadas

Entre os anos de 1943 e 1958 vários pesquisadores se destacaram por suas contribuições à construção do conhecimento de redes neurais artificiais. McCulloch e Pitts se destacaram por introduzirem a ideia de redes neurais como máquinas computacionais em 1943. Em 1958 Rosenblatt sobressaiu por propor o perceptron como o primeiro modelo para aprendizagem supervisionada. O perceptron é a forma mais simples de uma rede neural e consiste em um único neurônio com pesos sinápticos ajustáveis e bias. Nesse trabalho foram utilizadas redes neurais de múltiplas camadas (MLP-Multi layer perceptrons) que possuem uma grande habilidade de modelar sistemas complexos de uma maneira mais simples, além de possuírem um vasto número de aplicações. A Figura 4 mostra a estrutura de uma rede de perceptrons de múltiplas camadas com três entradas, dois neurônios na camada oculta e dois neurônios na camada de saída.

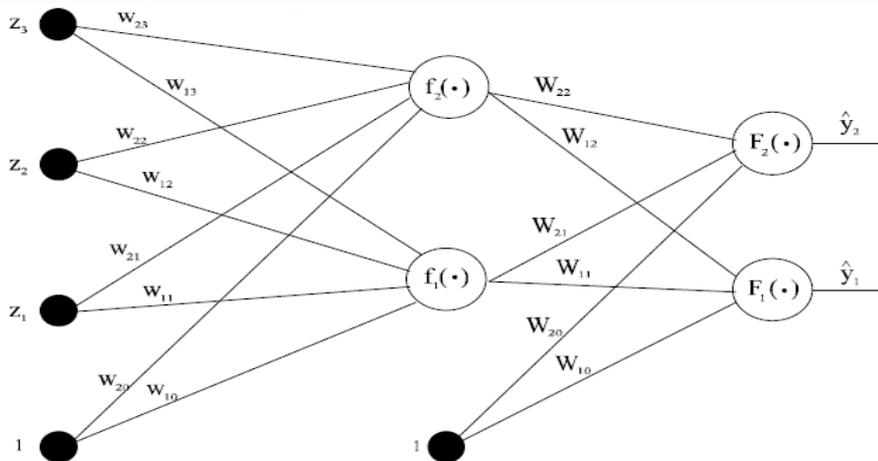


Figura 4 – Estrutura de uma rede do tipo MLP

A classe de redes de múltiplas camadas considerada nesse trabalho possui apenas uma camada de neurônios ocultos e trabalha somente com funções do tipo linear na saída e tangente hiperbólica na camada oculta.

Para o treinamento da rede é utilizado o algoritmo de retropropagação do erro (error back-propagation). Este algoritmo é baseado na regra de aprendizagem por correção de erro. Esse processo de aprendizagem pode ser dividido em duas etapas: propagação e retropropagação. Na primeira etapa um conjunto de dados de entrada é aplicado à rede e seu efeito se propaga camada por camada produzindo um conjunto de saídas como resposta.

Durante a etapa de propagação os pesos sinápticos são todos fixos. Durante a retropropagação os pesos sinápticos são ajustados de acordo com a regra de correção do erro. A resposta de saída da rede é subtraída de uma resposta desejada, produzindo um sinal de erro. Esse sinal se propaga para trás através da rede, contra a direção das conexões sinápticas. Dessa forma os pesos são ajustados com o objetivo de reduzir esse sinal de erro, fazendo com que a resposta da rede se aproxime cada vez mais da resposta desejada (HAYKIN, 1999).

3. PLANTA DIDÁTICA E MODELAGEM

A planta estudada neste trabalho está esquematizada na Figura 5. Ela possui um reservatório inferior (TQ-02) e um reservatório superior (TQ-01). O reservatório inferior é de aço inoxidável e fechado, o qual permite aumentar a temperatura do fluido através de um aquecedor (AQ-01) ou utilizá-lo como reservatório fechado ou aberto, através da válvula V-5.

Há uma bomba B-01 que retira o fluido da parte inferior de TQ-02 e o faz circular, através do trocador de calor (TC-01), pela válvula de controle superior (FV-01), pela placa de orifício (FE-01) e pela válvula V-7 que direciona o fluido dependendo da sua posição. Após passar pela válvula V-7, ou o fluido passa pela válvula de controle inferior (LV-01) e retorna ao reservatório inferior (TQ-02), ou passa pelo reservatório superior, depois pela válvula inferior (LV-01) e retorna ao (TQ-02).

A tubulação que direciona o fluido pelo reservatório superior será chamada de tubulação curta, uma vez que o caminho do fluido na tubulação é interrompido por TQ-01. O outro caminho será chamado de tubulação longa, visto que o fluido sai e retorna ao reservatório



inferior sem interromper seu caminho dentro da tubulação. As tubulações citadas acima podem ser identificadas na Figura 5 (WALLAS, 2010).

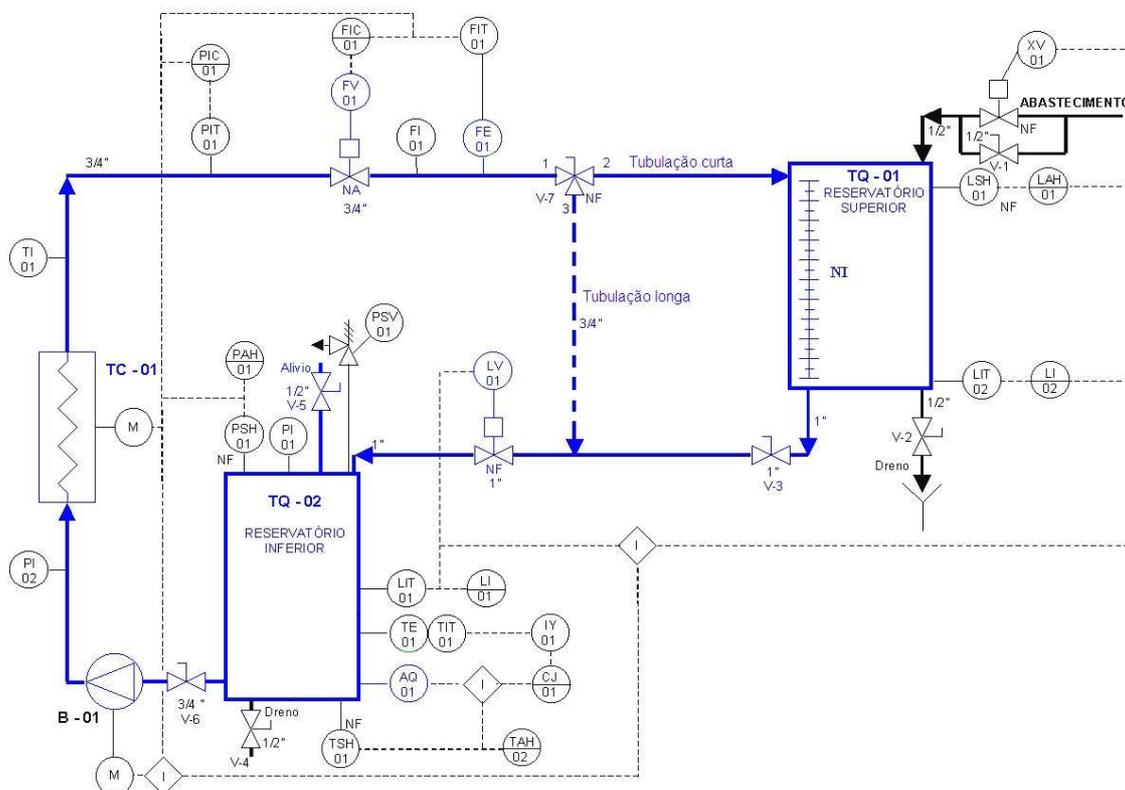


Figura 5 – Esquema da planta didática

O comportamento dinâmico da vazão e da pressão da planta didática tem característica não linear. Esse fato dificulta a modelagem do sistema através da análise física e matemática. A técnica de modelagem utilizada nesse trabalho é a identificação utilizando redes neurais artificiais do tipo perceptrons de múltiplas camadas (MLP). A metodologia utilizada pode ser descrita em cinco etapas: testes dinâmicos e coletas de dados, escolha de representação matemática a ser usada, determinação da estrutura do modelo, estimação dos parâmetros e validação do modelo.

Os testes dinâmicos e coletas de dados foram realizados conforme o procedimento descrito em (WALLAS, 2010): um sinal PRBS gerado, capaz de excitar as dinâmicas da planta sem introduzir um erro na identificação, foi aplicado na mesma a partir do supervisório In Touch e os dados das respostas a esse estímulo foram coletados, formando um vetor de entradas e saídas. O próximo passo é a escolha da representação matemática a ser usada. Nesse trabalho, o modelo utilizado para identificação de sistemas é o modelo ARX não linear, descrito pela Equação (1):

$$y(k) = \frac{B(q)}{A(q)} u(k) + \frac{1}{A(q)} v(k) \quad (1)$$



O valor de $u(k)$ corresponde à entrada do sistema, os valores de $y(k)$ correspondem à saída do sistema e o valor de $v(k)$ corresponde a um sinal de ruído e os polinômios $A(q)$ e $B(q)$ são expressões formadas pelo operador de atraso q conforme as Equações (2) e (3):

$$A(q) = 1 - a_1q^{-1} - \dots - a_{n_y}q^{-n_y} \quad (2)$$

$$B(q) = b_1q^{-1} + \dots + b_{n_u}q^{-n_u} \quad (3)$$

Os modelos ARX não lineares obtêm a saída y primeiramente a partir, do cálculo dos regressores para os valores de entradas e saídas atuais. Os regressores correspondem à entrada do bloco estimador não linear. O bloco do estimador não linear mapeia os regressores com as respectivas saídas do modelo através de uma combinação de funções lineares e não lineares. Os estimadores não lineares podem ser de diferentes tipos como redes neurais de múltiplas camadas, dentre outros. É utilizado no presente trabalho uma rede neural de múltiplas camadas como estimador não linear para identificação de sistemas a partir do Toolbox de identificação de sistemas baseado em redes neurais de Magnus Norgaard (NORGAARD, *et al.*, 2000). O algoritmo correspondente à versão do método de Levenberg-Marquardt, implementado por Magnus Norgaard. As estruturas NNARX (modelos ARX não lineares) com estimador linear correspondendo a uma rede neural de múltiplas camadas implementadas por Magnus Norgaard em seu Toolbox de identificação de sistemas baseado em redes neurais possuem vetor de regressão dado pela Equação 4 e a predição da saída $y(t)$ pelo estimador não linear dado pela Equação 5, onde θ representa o vetor de pesos sinápticos estimados.

$$\varphi(t) = [y(t-1) \dots y(t-n_a) u(t-n_k) \dots u(t-n_b-n_k+1)]^T \quad (4)$$

$$\hat{y}(t | \theta) = g(\varphi(t), \theta) \quad (5)$$

Após ter sido obtido um modelo é necessário verificar se o mesmo é válido, ou seja, se incorpora características do sistema original. O método mais comum de se realizar a validação de um modelo é através da investigação dos resíduos (erros de predição) do modelo identificado. Os resíduos são diferenças entre a saída um passo a frente prevista para o modelo e a saída medida a partir do conjunto de dados de validação do modelo.

4. RESULTADOS

4.1. Dinâmica da pressão de saída da bomba em função da variação da corrente de entrada

Após o treinamento da rede neural do tipo MLP com 6 neurônios na camada oculta, obteve-se um modelo ARX de segunda ordem com um atraso de primeira ordem. As figuras abaixo mostram os resultados do treinamento, comparando as respostas estimadas pela rede e a respostas reais esperadas e também o gráfico do erro. O treinamento foi realizado para as aberturas da válvula de vazão (FV-01) fixas em 20, 50 e 80% e variando-se a corrente de entrada num intervalo de 10 a 17 mA. Entretanto, os resultados mostrados aqui correspondem a abertura da válvula fixa em 20%. A Figura 6 mostra a resposta apresentada pelo modelo da rede neural bem como o gráfico do erro.

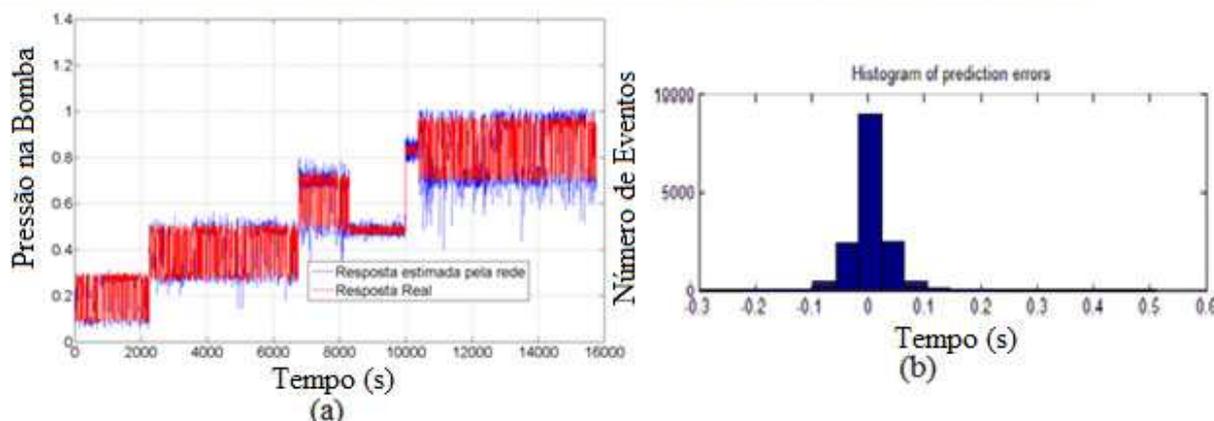


Figura 6 – (a) Comparação entre a resposta estimada pela rede neural (azul) e a resposta real (vermelho) e (b) o gráfico de erro

A Figura 7 mostra o resultado da modelagem utilizando o Toolbox de identificação de sistemas disponível no MATLAB, observa-se que não se obteve um bom modelo através desse método, pois ele possui uma ordem muito elevada (ARX[20 20 12]) e confiabilidade de apenas 53.38%. Isso comprova a eficiência da utilização de redes neurais artificiais no processo de modelagem do sistema não linear aqui descrito.

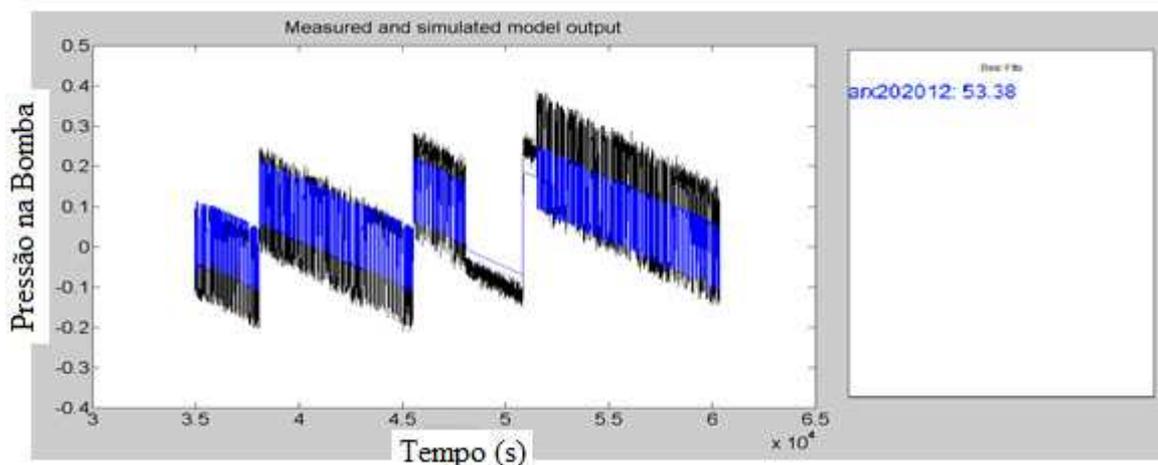


Figura 7 – Resultado utilizando a Toolbox de identificação de sistemas disponível no MATLAB

4.2. Dinâmica de vazão em função da abertura da válvula

Após o treinamento da rede neural do tipo MLP com 6 neurônios na camada oculta, obteve-se um modelo ARX de segunda ordem e com atraso de primeira ordem. A figura 8 mostra os resultados do treinamento, comparando as respostas estimadas pela rede e a respostas reais esperadas (a) e também o gráfico do erro (b). O treinamento foi realizado para as correntes de entrada da bomba fixas em 12, 14 e 16 mA e variando-se a abertura da válvula (FV-01) num intervalo de 10 a 70%. Todos os resultados dentro desse intervalo mostraram-se satisfatórios, entretanto, os resultados mostrados aqui correspondem a corrente de entrada da bomba fixa em 12 mA.

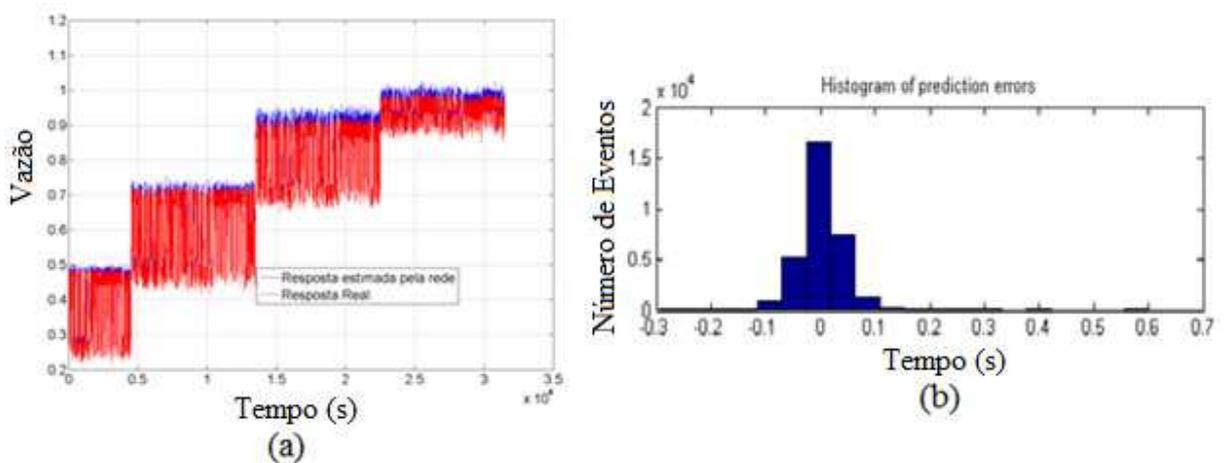


Figura 8 – (a) Comparação entre a resposta estimada pela rede neural (azul) e a resposta real (vermelho) e (b) gráfico de erro

A Figura 9 mostra o resultado da modelagem utilizando o Toolbox de identificação de sistemas disponível no MATLAB, observa-se que não se obteve um bom modelo através desse método, pois ele possui uma complexidade maior (ARX[20 18 11]) e confiabilidade de apenas 43.94%. Isso comprova a eficiência da utilização de redes neurais artificiais no processo de modelagem do sistema não linear aqui descrito.

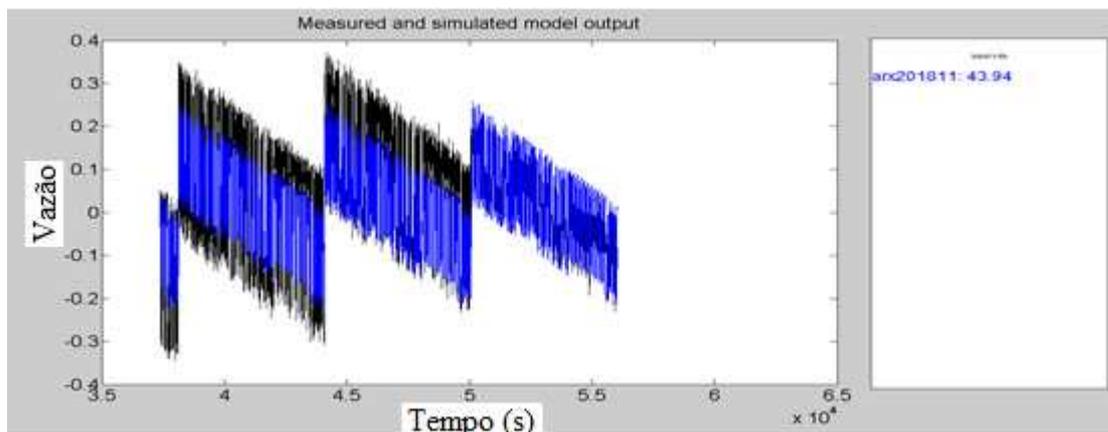


Figura 9 – Resultado utilizando a Toolbox de identificação de sistemas disponível no MATLAB

4. CONSIDERAÇÕES FINAIS

A modelagem de sistemas é importante para diversas aplicações na engenharia. Entretanto, durante o processo de modelagem podem surgir algumas dificuldades de se obter o modelo devido a complexidade do sistema e suas características relacionadas às não linearidades. Ao optar-se pelo método analítico, descrevendo o sistema através de equações físico-matemáticas pode-se deparar com a necessidade de estimar valores de constantes físicas e com a necessidade de resolução de equações matemáticas complexas. A identificação de sistemas se mostra vantajosa em relação a esse método, entretanto ao optar-se pelo método de



resposta ao degrau, por exemplo, há a necessidade de garantir que o sistema atue dentro da faixa de operação cujo seu comportamento é linear.

Diante de tantas questões e dos resultados apresentados acima, o uso da rede neural do tipo MLP mostrou-se eficiente no processo de modelagem das dinâmicas de pressão e vazão não-lineares de uma planta didática de controle de processos. Após o treinamento da rede (ajuste dos pesos sinápticos) obtiveram-se dois modelos do tipo ARX de segunda ordem com atraso que descrevem os sistemas apresentados garantindo uma pequena margem de erro, demonstrando o poder computacional das redes neurais artificiais no processo de modelagem.

REFERÊNCIAS BIBLIOGRÁFICAS

BOSTANCI, M., KOPLOWITZ, J., TAYLOR, C. W., - Identification of power system load dynamics using artificial neural networks. IEEE Trans. On Power Systems. v. 12, pp. 1468-1473, 1997.

COELHO, A.A.R., AND COELHO, L.S. – Sistemas Dinâmicos Lineares, 2004.

GILLARD, D. M., AND BOLLINGER, K. E., - Neural Networks identification of power system transfer function. IEEE Trans. On Energy Conversion. v. 11, pp. – 104-110, 1996.

HAYKIN, S., - Redes Neurais: Princípios e Práticas. Trad. Paulo Martins Engel, 2 ed Bookman, Porto Alegre, 1999.

HIYAMA, T., TOKIEDA, M., HUBBI, W. AND ANDOU, H., - Artificial Neural Network based dynamic load modeling. IEEE Trans. On Power Systems. v. 12, pp. 1576-1583, 1997.

HOSKINS, J.C., AND HIMMELBLAU, D.M., - Artificial Neural Network Models of Knowledge representation in chemical engineering. Comput. Chem. Eng. V.12, pp – 881-890, 1988.

McCULLOCH, W. S. AND W. PITTS, - A Logical Calculus of the Ideas Immanent in Neurons Activity. Bull Math. Biophys, v. 5, 1995.

NORGAARD, M. RAVN, O. POULSEN, N.K. AND HANSEN, L.K., Neural Networks for Modelling and Control of Dynamic Systems. Springer-Verlag, 2000.

WALLAS G. T., - Modelagem de uma planta didática multivariável e não-linear. Dissertação de Mestrado, Universidade Federal do Espírito Santo, 2010.



MODELING OF DYNAMIC PRESSURE AND FLOW CONTROL OF A PLANT TRAINING NONLINEAR PROCESS USING ARTIFICIAL NEURAL NETWORKS

Abstract : *The use of pilot plants in engineering education is essential for the establishment and demonstration of concepts learned in the classroom. For many applications such as process control is important to determine the mathematical model of the process in question. The aim of this study is to determine a mathematical dynamic model of pressure and flow for a didactic plant and nonlinear multivariable through the use of artificial neural networks. This plant is used for teaching in engineering control and automation of the IFES - SERRA (ES). Neural networks are algorithms that try to emulate in a very simplified way as the animal brain processes certain information and are based on elementary processors called neurons. In this study, we evaluated the ability of neural networks fashioning the process described by the didactic plant in question.*

Keywords: *Didactic Industrial Plant, Modeling, Artificial neural networks.*