

CALIBRAÇÃO DE MEDIDORES DE VAZÃO UTILIZANDO UM CONTROLADOR PID NEURAL

Paulo Thiago Fracasso, Bruno Castro Silva

Centro de Metrologia de Fluidos, Instituto de Pesquisas Tecnológicas do Estado de São Paulo
Av. Prof. Almeida Prado, 532 – Prédio 37
São Paulo, SP, Brasil

Anna Helena Reali Costa

Laboratório de Técnicas Inteligentes, Universidade de São Paulo
Av. Prof. Luciano Gualberto, 158 – Travessa 3
São Paulo, SP, Brasil

E-mails: ptf@ipt.br, brcastro@ipt.br, anna.reali@poli.usp.br

Resumo - Este artigo apresenta um controlador que realiza o ajuste automático da vazão e da pressão durante o processo de calibração de medidores de vazão. Este sistema fluídico possui longos tempos de atraso, grandes constantes de tempo e as variáveis controladas são fortemente correlacionadas, o que dificulta enormemente a ação do sistema de controle. O controlador proposto é inspirado em um PID neural, possui como variáveis de entrada a vazão e a pressão do medidor em teste, e as saídas são as velocidades de rotação do conjunto moto-bomba e o percentual de abertura de uma válvula de controle. Baseado em comparações entre o controlador proposto e um PID convencional os resultados demonstram a eficácia do sistema de controle para resolução de problema com múltiplos *set-points*.

Palavras Chaves - Controlador PID neural, calibração de medidores de vazão.

Abstract - This paper presents a controller that performs the automatic adjustment of flow and pressure during the flow meter calibration process. This fluidic system has long delay time, large time constants and the controlled variables are strongly coupled, which greatly hinder the action of the control system. The proposed controller is inspired in a neural PID, has as inputs the flow and the pressure in the test meter, and the outputs are the rotation speed of a motor-pump and the opening percentage of a control valve. Based on comparisons between the proposed controller and a standard PID results demonstrate the effectiveness of the control system for problem solving with multiple set points.

Keywords - PID controller, neural network, flow meter calibration.

1 INTRODUÇÃO

Antes de falarmos sobre o controlar PID ou redes neurais, devemos introduzir o termo metrologia. Segundo a definição, metrologia é a ciência das medições e abrange todos os aspectos teóricos e práticos que asseguram a exatidão nos processos produtivos e na transferência de custódia. Por meio dela é possível garantir a qualidade dos produtos e a lisura nas transações comerciais, onde sua principal ferramenta é a calibração dos instrumentos de medição associados, sejam eles analógicos ou digitais.

De forma simplista, a calibração de um instrumento corresponde à determinação das diferenças entre as medições realizadas por um medidor de referência e pelo medidor a ser calibrado, em toda a sua faixa de medição.

O Instituto de Pesquisas Tecnológicas (IPT), por meio do Centro de Metrologia de Fluidos, está construindo um novo laboratório de calibração de medidores de vazão de óleo. Este laboratório terá um sistema autônomo que possibilitará o controle da grandeza a ser calibrada, no caso vazão de óleo, além também do ajuste da pressão na linha de teste, proporcionando a calibração na condição de operação do medidor, a diminuição do tempo de ajuste do ponto de calibração e a repetitividade do processo.

O controlador proposto é inspirado em um PID neural, possui como variáveis de entrada a vazão e a pressão no medidor em teste, e as variáveis de saídas são as velocidades de rotação do

conjunto moto-bomba e o percentual de abertura de uma válvula de controle, conforme Figura 1.

Diferentemente das abordagens de controladores PID neurais de Shu e Pi [2005], Xie, Quan e Chen [2008] e Yu e Shu [2008], o controlador proposto possui as seguintes características: função de ativação nos neurônios das camadas de entrada e escondida, *bias* no neurônio da camada de saída e pesos fixos na camada de entrada.

Este trabalho está organizado da seguinte forma: Na seção 2 é apresentada uma breve descrição sobre a dinâmica de sistemas fluídicos. A seção 3 descreve o controlador PID neural proposto. Já as seções 4 e 5 apresentam a metodologia e os resultados dos experimentos realizados. Finalmente, a seção 6 apresenta as conclusões e considerações finais a respeito do sistema de controle proposto.




Figura 1 – Sistema de calibração de medidores de vazão.

2 MODELAGEM DA DINÂMICA DE SISTEMAS FLUÍDICOS

Perda de carga é o termo que descreve o decremento da pressão de um escoamento em dois pontos distintos e pode ser interpretada como a quantidade de energia perdida de um sistema fluídico por fricção das moléculas nas paredes de uma tubulação [Idelchik, 1969]. O equacionamento da perda de carga nos permite modelar o sistema fluídico.

O cálculo da perda de carga numa seção uniforme de uma tubulação, do ponto A para o ponto B, é realizada conforme a equação:

$$\Delta P = P_B - P_A = -\rho \cdot g \cdot \left(Z_B - Z_A + \frac{f \cdot L \cdot V^2}{2 \cdot D \cdot g} \right) \quad (1)$$

onde P_A e P_B são as pressões absolutas nos pontos A e B, Z_A e Z_B são as cotas dos pontos A e B, ρ é a massa específica do fluido, g é a aceleração da gravidade local, f é o fator de atrito, L é o comprimento do tubo, V é a velocidade do escoamento e D é o diâmetro do tubo.

No caso de escoamentos laminares, com número de Reynolds menor que 3500, temos que o fator de atrito será:

$$f = \frac{64}{Re} \quad (2)$$

No caso de escoamentos turbulentos, com número de Reynolds maior que 3500, temos que o fator de atrito será:

$$\frac{1}{\sqrt{f}} = -2 \cdot \log \left(\frac{e/D}{3,7} + \frac{2,51}{Re \cdot \sqrt{f}} \right) \quad (3)$$

onde e/D é a rugosidade relativa da tubulação e Re é o número de Reynolds do escoamento.

Por sua vez, o número de Reynolds é calculado pela seguinte equação:

$$Re = \frac{\rho \cdot V \cdot D}{\mu} = \frac{V \cdot D}{\nu} \quad (4)$$

onde μ e ν são as viscosidades dinâmica e cinemática do fluido, respectivamente.

Já o cálculo da perda de carga em uma válvula ou uma singularidade qualquer, por exemplo, expansão, cotovelo, tee, etc, é calculada da seguinte forma:

$$\Delta P = P_B - P_A = \left(\frac{Q}{CV} \right)^2 \cdot \rho \quad (5)$$

onde Q é a vazão e CV é o coeficiente de vazão que é determinado experimentalmente para cada tipo de válvula ou singularidade.

Por exemplo, a Figura 2 apresenta a curva de perda de carga de um sistema constituído por um trecho de tubo e por uma válvula. O eixo das abscissas corresponde ao percentual de abertura desta válvula, onde o valor 1 corresponde à válvula totalmente aberta e zero corresponde à válvula totalmente fechada. Já o eixo das ordenadas representa a perda de carga.

Por outro lado, um conjunto moto-bomba apresenta curva característica, pressão de recalque em função da vazão conforme Figura 3 (obtida de forma experimental). Nesta

figura pode-se observar que quanto maior a vazão, menor será a pressão de recalque e quanto maior a pressão de recalque, menor será a vazão. Além disso, conforme se diminui a velocidade de rotação do motor, desloca-se a curva característica do conjunto moto-bomba para a origem.




Figura 2 – Curva de perda de carga do sistema.




Figura 3 – Curva do conjunto moto-bomba.

Sendo assim, o ponto de operação de um sistema fluídico será o cruzamento da curva de perda de carga do sistema com a curva de recalque do conjunto moto-bomba [Garcia, 1997], conforme exemplo apresentado na Figura 4.




Figura 4 – Ponto de operação de um sistema fluídico.

3 PID NEURAL

O controlador PID neural, conforme Figura 5, nada mais é que uma rede neural de 3 camadas composta de diversas sub-redes, cada uma com um PID emulado na camada escondida, e interligadas por meio da camada de saída.




Figura 5 – Estrutura de um PID neural.

Cada sub-rede possui 2 neurônios na camada de entrada, que recebem os valores da variável controlada y e do seu respectivo *set-point* r . Já a camada escondida possui 3 neurônios com funções de entrada/saída composta por funções proporcional (P), integral (I) e derivativo (D). Finalmente, na camada de saída há apenas um neurônio, que pondera o valor das saídas dos neurônios proporcional, integral e diferencial de todas as sub-redes e fornece à entrada do sistema a ser controlado, conforme Figura 6.




Figura 6 – Sub-rede de um PID neural.

No controlador baseado em um PID neural, o número de neurônios dentro de cada camada, o método de conexão e seus respectivos pesos são determinados pelo princípio básico de um PID clássico e da experiência anterior, possibilitando a

estabilidade e convergência do sistema sem a necessidade da determinação de constantes ou o conhecimento prévio do modelo do sistema a ser controlado.

A grande vantagem da utilização de um PID neural em relação a um PID convencional é a rapidez na sua implementação, haja visto que não é necessária a configuração das constantes P, I e D. Além disso, não é necessário encontrar novas constantes quando o *set-point* é alterado, dado que pode-se treinar o PID neural em diversos pontos de operação.

Resumidamente, o PID neural é um PID convencional, cujos ganhos são alterados por um algoritmo neural a partir dos dados de entrada e saída do ciclo anterior. Este processo se repete após cada operação, ou seja, os ganhos são alterados após um ciclo completo e antes do início da próxima batelada. Sendo assim se o mesmo *set-point* for repetido em diversas iterações o algoritmo neural otimiza os ganhos integral, proporcional e derivativo para aquelas condições de operação.

3.1 Algoritmo

Seja um sistema a ser controlado com m entradas e l saídas, o PID neural será composto de l sub-redes e m saída. A função do PID neural, no tempo k , é dada por:

a) Camada de entrada:

A camada de entrada possui $2l$ neurônios iguais e a função entrada/saída é dada por:

$$x_{si}(k) = u_{si}(k) \quad (6)$$

Na formula $u_i(i=1,2)$ é o valor de entrada do neurônio na camada de entrada, $x_i(i=1,2)$ é o valor de saída do neurônio na camada de entrada, s é o número da sub-rede, e também é número da variável controlado, $s=1,2,...,l$.

b) Camada escondida:

A camada escondida do PID neural é composto por $3l$ neurônios, no qual, l neurônios são proporcionais, l neurônios são integrativos e l neurônios são derivativos. A função de entradas de todos é a mesma é dada por:

$$u_{sj}'(k) = \sum_{i=1}^2 w_{sij} \cdot x_{si}(k) \quad (7)$$

Já a função entrada/saída da camada escondida pode ser de três tipos:

Proporcional:

$$x_{s1}'(t) = \phi(u_{s1}'(t)) \quad (8)$$

Integral:

$$x_{s2}'(t) = \phi\left(\int u_{s2}'(t)dt\right) \Leftrightarrow x_{s2}'(k) = \phi(x_{s2}'(k-1) + u_{s2}'(k)) \quad (9)$$

Diferencial:

$$x_{s3}'(t) = \phi\left(\frac{d}{dt} u_{s3}'(t)\right) \Leftrightarrow x_{s3}'(k) = \phi(u_{s3}'(k) - u_{s3}'(k-1)) \quad (10)$$

Nas funções acima $s=1,2,...,l$ representa o número das sub-redes paralelas, $j=1,2,3$ o número do neurônio na camada escondida, w_{sij} o peso entre a camada de entrada e a camada escondida de cada sub-rede, e $\phi(.)$ é a função de ativação do neurônio. O apostrofe representa que a variável está na camada escondida.

c) Camada de saída:

A camada de saída do PID neural possui m neurônios, que formam m saídas. Não há relação direta entre o número do neurônio de saída e o número da sub-rede, e a entrada de neurônio da camada de saída é a soma ponderada de todos os neurônios da camada escondida, conforme equação abaixo:

$$u''(k) = \sum_{s=1}^l \sum_{j=1}^3 w_{sjh}' \cdot x_{sj}'(k) \quad (11)$$

A função entrada/saída dos neurônios da camada de saída é dada por:

$$x_h''(k) = \varphi(u_h''(k)) \quad (12)$$

Estes valores de saída da rede são as entradas do sistema a ser controlado. Nesta fórmula $h = 1, 2, \dots, m$ representa o número do neurônio na camada de saída, w_{sjh}' representa os pesos entre a camada escondida e a camada de saída. Os dois apóstrofes representam as variáveis na camada de saída.

d) Função de ativação:

Os neurônios das camadas escondida e de saída estão sujeitos a uma função de ativação. Neste artigo a função de ativação escolhida foi a tangente hiperbólica.

$$\varphi(x(k)) = a \cdot \tanh(b \cdot x(k)) \quad (13)$$

Na equação acima os valores de a e b são iguais a 1 o que faz com a função de ativação seja limitada no intervalo $[-1; 1]$.

e) Bias:

O *bias* é uma entrada unitária nos neurônios das camadas escondida e de saída e possibilita o deslocamento da função de ativação em relação ao somatório das entradas [Haykin, 2008]. Esse deslocamento é influenciado pelo seu respectivo peso e que é constantemente alterado pelo algoritmo de *back-propagation*. Este artifício não é utilizado na camada de entrada, pois induziria um erro estacionário no sistema em malha fechada.

3.2 Algoritmo de *back-propagation* do PID neural:

O algoritmo descrito a seguir é responsável por alterar os pesos da rede neural com base nos resultados obtidos na simulação anterior. O objetivo de aprendizado do PID neural é minimizar o erro quadrático médio das entradas do sistema, conforme abaixo:

$$J = \sum_{s=1}^l E_s = \sum_{s=1}^l \sum_{k=1}^n e_s^2(k) = \frac{1}{n} \sum_{s=1}^l \sum_{k=1}^n [r_s(k) - y_s(k)]^2 \quad (14)$$

Na fórmula acima, n representa o número de amostras no tempo, s o número de variáveis controláveis e k o ponto de amostragem. O peso pode ser determinado após n_0 passos de treinamento e a fórmula de aprendizado é dividida em duas partes:

Para o cálculo dos novos pesos entre a camada escondida e a camada de saída, utiliza-se a seguinte fórmula iterativa:

$$w_{sjh}'(n_0 + 1) = w_{sjh}'(n_0) - \eta_{sjh}' \frac{\partial J}{\partial w_{sjh}'}, \quad (15)$$

Na fórmula acima temos:

$$\frac{\partial J}{\partial w_{sjh}'} = \frac{\partial J}{\partial y_s} \frac{\partial y_s}{\partial x_h''} \frac{\partial x_h''}{\partial u_h''} \frac{\partial u_h''}{\partial w_{sjh}'} = -\frac{1}{n} \sum_{k=1}^n \delta_h' \cdot x_{sj}'(k) \quad (16)$$

$$\delta_h' = [r_s(k) - y_s(k)] \cdot \left(\frac{b}{a}\right) \cdot (a - y_h(k)) \cdot (a + y_h(k)) \quad (17)$$

Os pesos dos neurônios da camada de entrada não são alterados, mantendo estes sempre fixo no valor:

$$w_s'(n_0 + 1) = w_s'(n_0) = \begin{bmatrix} -1 & -1 & -1 \\ 1 & 1 & 1 \end{bmatrix} \quad (18)$$

onde, $s(=1, 2, \dots, l)$ representa o número da sub-rede e da variável controlável.

Desta forma a saída da camada de entrada será sempre o erro das variáveis controladas, ou seja, a diferença entre o valor atual e o seu *set-point*.

4 METODOLOGIA

Baseados nos conceitos apresentados sobre a dinâmica de sistemas fluidicos foi desenvolvido um sistema de controlador inspirado em redes neurais artificiais onde as variáveis controladas são a vazão e a pressão na linha de teste. Já as variáveis de saídas deste controlador neural são a rotação do conjunto moto-bomba e o percentual de abertura de uma válvula de controle.

Desta forma, foram utilizadas duas sub-redes com PID neurais interligados por meio da camada de saída. Nas entradas da primeira sub-rede temos o valor da pressão na linha de teste e de seu respectivo valor de *set-point*. Já nas entradas da segunda sub-rede temos o valor da vazão e de seu respectivo valor de *set-point*. Finalmente, a saída da primeira sub-rede é o percentual de abertura da válvula de controle e a saída da segunda sub-rede é a velocidade de rotação do conjunto moto-bomba, conforme Figura 7.




Figura 7 – Sistema de controle.

Para que seja possível avaliar o desempenho do controlador PID neural foi necessário definir um parâmetro de comparação, para tanto, neste trabalho foi utilizado o controlador PID convencional, conforme Figura 8.




Figura 8 – Sistema de controle com PIDs convencionais.

Este tipo de controlador domina as malhas de controle industriais [Ogata, 2009] e é formado por duas malhas de controle independentes, o que representa uma grande desvantagem em relação ao método proposto.

A implementação de um controlador do tipo PID é muito simples e conhecida. Entretanto, é necessário definir os parâmetros do controlador, de modo a se obter uma boa resposta em malha fechada. No modelo proposto são necessários dois controladores PID, que devem ser sintonizados isoladamente.

Existem algumas técnicas básicas para realizar a sintonia de um controlador PID. Dentre elas estão: método da sensibilidade limite (normal e modificado) [Aström e Hägglund, 1995], método da curva de reação [Aström e Hägglund, 1995], método do relê [Aström e Hägglund, 1995], método da síntese direta [Seborg, Edgar e Mellichamp, 1989], entre outros.

O método da síntese direta foi a técnica que forneceu os melhores resultados para o controle deste sistema fluídico. Para aplicar esta técnica as malhas foram aproximadas por dois sistemas de primeira ordem. As constantes de tempo de malha fechada foram consideradas como sendo 2 segundos para malha de controle de pressão e 1,5 segundo para malha de controle de vazão. O resultado são dois controladores PI (ganho derivativo é nulo). Os ganhos foram calculados em torno de 700 m³/h de vazão e 5 bar de pressão.

5 RESULTADOS

A seguir são apresentados os resultados para a simulação do sistema de controle proposto e do PID convencional para os seguintes valores de *set-point*: 200 m³/h de vazão e 8 bar de pressão, entre 0 e 60 segundos, e 700 m³/h de vazão e 5 bar, entre 60 e 120 segundos. Todos os experimentos e simulação foram realizados no software Simulink do MatLab, com passo de tempo de 100ms, duração de 120s e 100 épocas de treinamento.

As Figuras 9 e 10 apresentam os resultados da atuação dos dois sistemas de controle nas variáveis vazão e pressão, respectivamente, em função do tempo. Já a Figura 11 apresenta o erro quadrático médio dos controladores, onde observa-se que em torno de 30 segundos é possível obter os valores de *set-point*.




Figura 9 – Curva de vazão em função do tempo.




Figura 10 – Curva de pressão em função do tempo.




Figura 11 – Erro quadrático médio em função do tempo.

Podemos observar que para o ponto de operação da sintonia do PID multi-malhas o sistema neural apresente desempenho inferior ao sistema padrão. Ambos atingem o *set-point*, entretanto o PID o faz muito mais rápido. No outro ponto de operação por sua vez é clara a diferença entre os dois sistemas. Enquanto o sistema com PIDs simples oscila em torno do *set-point*, o PID neural atinge novamente o valor desejado. Isto ocorre devido ao fato de que para o segundo ponto de operação (para o qual o PID convencional foi projetado) são necessários ganhos maiores, mas para o primeiro ponto estes mesmos ganhos são muito agressivos. O PID neural, por sua vez, calcula os ganhos de PID que minimizam o erro quadrático durante a fase de treinamento. Este ganho como se pode ver é mais suave que o obtido pelo método da síntese direta atendendo a ambos os pontos de operação.

6 CONCLUSÃO

Neste trabalho foi apresentada uma técnica para resolução do problema de ajuste automático da vazão e pressão de um sistema fluídico atuando em uma válvula de controle e na velocidade de rotação de uma moto-bomba.

Mesmo com os longos tempos de atraso, as grandes constantes de tempo associadas e a forte correlação entre as variáveis do sistema, o controlador proposto apresentou ótimos resultados,

mostrando-se eficaz para a tarefa proposta, principalmente com um sistema de múltiplos *set-points*.

Outra vantagem apresentada é a inexistência de ajuste de constantes de tempo e o conhecimento prévio do modelo do sistema, típicos em outras técnicas. Desta forma, o controlador neural é facilmente implementado.

Os sistemas PIDs convencionais apresentam um desempenho superior ao método proposto caso estejam atuando próximo do ponto de operação em que foi projetado (considerando sistemas com fortes não-linearidades). Entretanto em pontos diferentes, onde as características do sistema a ser controlado são distintas, ele se mostra ineficiente. Desta forma, é possível concluir que o PID neural é mais robusto e indicado para sistemas não lineares em que a faixa de operação é abrangente.

REFERÊNCIA BIBLIOGRÁFICA

- Aström, K. J. and Hägglund, T. PID Controllers - Theory, Design and Tuning. 2nd edition, Instrument Society of America, 1995.
- Garcia, Claudio. Modelagem e Simulação de Processos Industriais e de Sistemas Eletromecânicos, 2^a edição, Editora USP, 1997.
- Haykin, Simon. Neural Networks and Learning Machines. Prentice Hall, 3rd edition, 2008.
- Idelchik, I.E. Memento des Pertes de Charges - Coefficients de Pertes de Charge Singulières et de Pertes de Charge par Frottement. Eyrolles, 1969.
- Ogata, Katsuhiko. Modern Control Engineering. Prentice Hall, 5th edition, 2009.
- Seborg, D. E.; Edgar, T. F.; Mellichamp, D. A. Process Dynamic and Control. New York: John Wiley & Sons, 1989.
- Shu, Huailin and Pi, Youguo. Decoupled Temperature Control System Based on PID Neural Network. International Conference on Automatic Control and Systems Engineering, 2005.
- Xie, Chang-Jun; Quan, Shu-Hai and Chen, Qi-Hong. Control Strategy of Hybrid Power System for Fuel Cell Electric Vehicle Based on Neural Network Optimization. Proceedings of the IEEE International Conference on Automation and Logistics. Qingdao, China, pp. 753-757, 2008.
- Yu, Qun and Shu, Hua. Development of PID Neural Network Control System with Virtual Instrument. 2008 International Seminar on Future BioMedical Information Engineering, pp. 425- 428, 2008.