

SISTEMA DE CONTROLE INFERENCIAL APLICADO NO AJUSTE DA CONCENTRAÇÃO E PRODUÇÃO DE MISTURAS

José Medeiros de Araújo Júnior, medeiros_eng@yahoo.com.br¹
Leandro Luttiane da Silva Linhares, leandroluttiane@yahoo.com.br¹
Fábio Meneghetti Ugolino de Araújo, meneghet@dca.ufrn.br¹

¹ Departamento de Engenharia de Computação e Automação, Centro de Tecnologia, Universidade Federal do Rio Grande do Norte, 59078-900, Natal – RN – Brasil.

Resumo: Plantas que efetuam a mistura de compostos com o objetivo de obter um determinado produto são encontradas em diversos ramos da indústria, como por exemplo, a petroquímica, a alimentícia, a de revestimentos, entre outras. O processo utilizado neste trabalho corresponde à uma simulação genérica de um sistema de mistura formado por dois tanques em série e alimentados, através de duas bombas de sucção, por dois produtos distintos que quando misturados formam o produto final do processo. Para controlar a concentração e o nível de produção desse produto, é utilizado, neste trabalho, um sistema de controle inferencial. De uma forma geral, esse tipo de sistema de controle envolve a síntese de um controlador e o projeto de um sistema de inferência, sendo este último responsável por estimar as variáveis do processo de difícil mensuração ou que apresentem longos atrasos de medição. O sistema de controle inferencial proposto é formado por um controlador fuzzy realimentado pelos valores de concentração e nível de produção da mistura final do processo, que são fornecidos por um sistema de inferência baseado em redes neurais artificiais. Essas variáveis são estimadas a partir dos níveis dos tanques. Os valores inferidos são então comparados com os seus valores de referência e a partir dos erros resultantes o controlador fuzzy ajusta adequadamente os set points dos controladores PIDs presentes na malha regulatória do processo.

Palavras-chave: controle inferencial, controlador fuzzy, redes neurais, mistura de compostos.

1. INTRODUÇÃO

O crescente aumento da concorrência econômica aliado ao avanço tecnológico no ramo da automação e computação, fazem com que as indústrias que pretendem se manter competitivas no mercado estejam sempre em busca de desenvolver ou utilizar ferramentas mais eficientes para monitorar e controlar os seus processos.

Observa-se, em alguns processos, uma grande dificuldade em mensurar ou estimar algumas de suas variáveis mais importantes. De acordo com Warne et al. (2004), isso se deve, geralmente, às limitações tecnológicas do processo ou das técnicas de medição. Essas variáveis de difícil medição, frequentemente, estão relacionadas com as especificações de qualidade da produção, sendo, portanto, de importante interesse econômico.

Na indústria petroquímica, por exemplo, raramente, a composição química de seus produtos finais são usadas diretamente como variáveis controladas, pois é difícil a medição exata dessas variáveis em tempo real (Evangelista et al., 2001). As composições químicas desses produtos são, geralmente, os principais indicadores da performance do processo, sendo mensuradas através de análises laboratoriais ou de instrumentos como os cromatógrafos à gás. Segundo Joseph (1999), os cromatógrafos são equipamentos que apresentam alto custo de aquisição e de manutenção, além de apresentarem longos intervalos de medição. Devido a esses tipos de questões técnicas que em alguns processos é encontrada uma limitação considerável na possibilidade de implementar sistemas de controle e de supervisão mais eficientes que proporcionariam o melhor rendimento do processo.

Segundo Zamproga et al. (2005), os sistemas de inferência representam uma abordagem atrativa para estimar as variáveis primárias do processo, particularmente quando não existem sensores físicos convencionais para a medição dessas variáveis, ou quando seu alto custo ou limitações técnicas impedem o seu uso em tempo real. Os sistemas de inferência fazem uso do conhecimento do processo, incluindo o seu modelo e medições confiáveis e de fácil obtenção de variáveis secundárias do processo, tais como temperaturas, níveis, pressões, vazões e outros, para estimar as variáveis primárias de interesse. Partindo desse princípio, pode-se afirmar que um sistema de inferência funcional corresponde a um modelo capaz de representar adequadamente as relações dinâmicas existentes entre as variáveis secundárias e primárias do processo, o que torna explícito a necessidade de identificar o comportamento dinâmico do processo físico a ser estudado (Linhares et al., 2008). A inferência de características pouco acessíveis do processo

permite que esse possa ser controlado/supervisionado com maior eficiência. A estratégia de controle, que se utiliza de estimativas fornecidas por sistemas de inferência, é denominado controle inferencial (Joseph, 1999).

Apesar dos sistemas inferenciais serem amplamente utilizados nas indústrias, Fortuna et al. (2007a) afirmam que são três as principais metodologias para o desenvolvimento de sistemas inferenciais: modelagem fenomenológica, métodos de regressão estatística multivariáveis, tais como PCR e PLS, e a modelagem a partir de alguma técnica de inteligência artificial, tais como redes neurais artificiais, lógica *fuzzy* e métodos híbridos.

Neste trabalho é utilizado um sistema de inferência baseado em redes neurais artificiais com o objetivo de estimar o nível de produção e a concentração da mistura de um sistema de tanques acoplados em escala de laboratório, desenvolvido para servir de plataforma para a implementação e avaliação de diferentes estratégias de controle em um processo multivariável. O processo de tanques acoplados é bastante adequado para ser utilizado neste tipo de estudo, pois é bastante comum em escala industrial, principalmente nos ramos petroquímicos (Garcia, 1997). A partir dessas variáveis estimadas, pretende-se realizar o controle inferencial dessas variáveis a partir de um controlador *fuzzy* que irá atuar sobre os controladores PIDs presentes na malha regulatória do processo. As redes neurais são amplamente utilizadas na implementação de sistemas de inferência e o sucesso de sua aplicação tem sido relatado para diferentes processos (Bo et al., 2003; Chella et al., 2006; Fortuna et al., 2007b).

Nos últimos anos, os controladores *fuzzy* estão se tornando cada vez mais populares por sua fácil e rápida implementação. Com o avanço das tecnologias, podemos encontrar no mercado, controladores que utilizam dessa tecnologia, tendo um alto índice de confiabilidade. A disponibilidade de recursos computacionais de alta performance possibilita o uso de ferramentas que necessitam de um custo computacional alto, reduzindo um problema com alto grau de complexidade de implementação para um de menor grau.

Segundo Bittencourt e Osório (2002), os controladores *fuzzy* estão sendo utilizados largamente em diversas indústrias e processos, chamando a atenção de empresas e pesquisadores. A supervisão e controle de processo remotamente, através de uma rede industrial, possibilitam a intervenção imediata, não sendo necessário refazer um determinado hardware ou modelar novamente um processo específico, economizando tempo e retrabalho, resultando em uma melhor adequação do sistema em uma planta industrial.

2. SISTEMA DE TANQUES ACOPLADOS

O sistema simulado neste trabalho tem como base o *kit* de tanques acoplados da Quanser (Quanser Cooperation, 1998), adicionando-se ao mesmo mais uma bomba de sucção. O sistema educativo original tem como objetivo principal o estudo de sistemas de controle, através do controle de nível de seus tanques. Neste trabalho, pretende-se simular um sistema de mistura hipotético, onde o objetivo é controlar a produção e concentração dessa mistura. A Figura (1), apresenta o sistema proposto.




Figura 1. Diagrama esquemático do sistema de mistura.

O sistema é formado por dois tanques cilíndricos alimentados por duas bombas distintas. O tanque 1 recebe um dos compostos que formam o produto final. O tanque 2 recebe além do segundo composto, a vazão de saída do tanque 1. A bomba 2 não realiza sucção no sentido inverso, pois tal procedimento acarretaria em contaminação do líquido presente no reservatório 2, que contém o segundo composto da mistura.

O modelo discretizado do sistema é apresentado pelas Eqs. (1) e (2), onde L_1 e L_2 correspondem aos níveis dos tanques 1 e 2, e V_{p1} e V_{p2} as tensões de alimentação das bombas dos tanques 1 e 2, respectivamente.

$$L_1(k) = 0,9935 L_1(k-1) + 0,02955 V_{p1}(k-1) \quad (1)$$

$$L_2(k) = 0,006522 L_1(k-1) + 0,9935 L_2(k-1) + 0,00009687 V_{p1}(k-1) + 0,02955 V_{p2} \quad (2)$$

A partir do conhecimento físico do sistema, pode-se, através das Eqs. (3) e (4), encontrar os fluxos de entrada do tanque 1 ($F1_{in}$) e o de saída do tanques 2 ($F2_{out}$), considerando o sistema em regime permanente. Das referidas equações tem-se que g é a aceleração da gravidade, e a_1 e a_2 são, respectivamente, os diâmetros de saída dos tanques 1 e 2.

$$F1_{in} = a_1 \sqrt{2gL_1} \quad (3)$$

$$F2_{out} = a_2 \sqrt{2gL_2} \quad (4)$$

Partindo dos resultados das equações acima, são calculados o fluxo de saída da produção e a concentração da mistura através das Eqs. (5) e (6). Onde P é o nível de produção e C_1 a concentração do composto 1 na mistura. Deve-se lembrar que $C_1 + C_2 = 1$.

$$P = F2_{out} \quad (5)$$

$$F1_{in} = C_1 F2_{out} \quad (6)$$

3. SISTEMA DE CONTROLE INFERENCIAL PROPOSTO

O sistema de controle inferencial proposto neste trabalho é apresentado esquematicamente na Fig. (2). O objetivo do sistema é controlar adequadamente o nível de produção e a concentração da mistura obtida ao final do processo. Os níveis dos tanques são controlados por controladores PIDs, através da aplicação de tensões V_{p1} e V_{p2} às bombas que alimentam os tanques. A partir do tanque 2, último estágio do processo, são obtidos através da simulação, os valores aproximados de P e C , variáveis primárias do processo. A partir de L_1 e L_2 , variáveis secundárias, o sistema de inferência neural calcula as estimativas \bar{P} e \bar{C} . A partir dessas informações, e dos valores desejados para as variáveis primárias do processo, o controlador *fuzzy* inferencial fornece incrementos/decrementos aos *set points* dos controladores PIDs, atuando, dessa forma, sobre a malha de controle regulatória do processo.

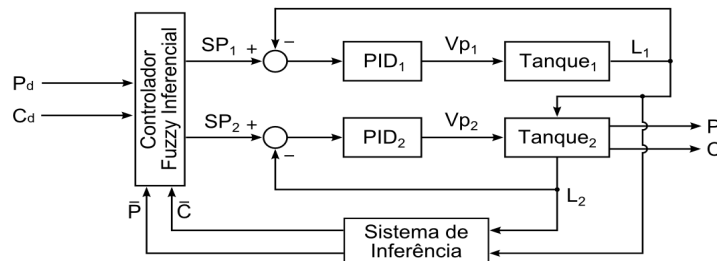


Figura 2. Sistema de controle proposto.

3.1. Sistema de inferência neural

Um sistema de inferência nada mais é do que um modelo capaz de representar as dinâmicas existentes entre as variáveis primárias do processo, sendo essas geralmente de difícil mensuração, e as variáveis secundárias do processo. Estas são facilmente obtidas, tais como, temperaturas, pressões, vazões e níveis. Dessa forma, é necessário realizar a identificação dinâmica do sistema em estudo.

O procedimento de identificação dinâmica exige que, inicialmente, seja selecionada a estrutura ou o modelo de identificação que será utilizado. De forma geral, o problema da seleção desse modelo pode ser dividido em duas partes: selecionar uma família de estruturas de modelagem apropriada para descrever os comportamentos dinâmicos e em seguida escolher um subconjunto dessa família de estruturas de modelagem (Nørgaard et al., 2001).

Na família das redes neurais perceptron de múltiplas camadas (PMC), tem-se como exemplos de modelos de identificação que podem ser adotados: NNFIR, NNARX, NNARMAX, NNOE, NNSSIF e algumas variações e hibridizações dessas estruturas. O modelo utilizado pelo sistema de inferência deste trabalho é o modelo NNARX.

A identificação realizada neste trabalho é efetuada tomando como base apenas dados experimentais coletados do processo. Portanto, o primeiro passo a ser tomado nesse tipo de procedimento é obter as amostras necessárias para a identificação de tal forma que seja possível a caracterização de sua dinâmica. Para isso, devem ser aplicados ao sistema

sinais de excitação ricos em frequências. Um sinal muito utilizado na prática, por possuir essas características, é o PRS (*Pseudo Random Signal*).

A Figura (3) apresenta a estrutura do sistema de inferência, seguindo o modelo NNARX, utilizado neste trabalho. Onde a RNA é a PMC e n representa os regressores aplicados às variáveis de entrada da rede neural. Não sendo considerado possíveis atrasos de transporte do sistema. Os regressores presentes nesse modelo permitem que a rede neural seja capaz de representar o comportamento de sistemas dinâmicos.

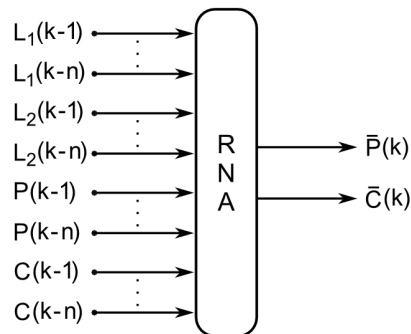


Figura 3. Estrutura do sistema de inferência utilizado.

3.2. Controlador Fuzzy

Um controlador *fuzzy* é um sistema *fuzzy* à base de regras, composto de um conjunto de regras de produção do tipo SE <premissa> ENTÃO <Conclusão>, que definem ações de controle em função das diversas faixas de valores que as variáveis de estado do problema podem assumir (Klir *et al*, 1988, D'Amore *et al*, 1997). Essas faixas de valores são denominadas termos lingüísticos.

Formalmente, um conjunto *fuzzy* A do universo de discurso Ω é definido por uma função de pertinência $\mu_A: \Omega \rightarrow [0,1]$. Essa função associa a cada elemento x de Ω o grau $\mu_A(x)$, com o qual x pertence a A . A função de pertinência de $\mu_A(x)$ indica o grau de compatibilidade entre x e o conceito expresso por A .

Segundo Shaw (1999), as funções de pertinência *fuzzy* representam os aspectos fundamentais de todas as ações teóricas e práticas de sistemas *fuzzy*. Uma função de pertinência é uma função numérica, gráfica ou tabulada que atribui valores de pertinência *fuzzy* para valores discretos de uma variável em seu universo de discurso. É preciso lembrar que o universo de discurso de uma variável representa o intervalo numérico de todos os possíveis valores reais que uma variável específica pode assumir.

Ao contrário dos controladores convencionais, em que o algoritmo de controle é descrito analiticamente por equações algébricas ou diferenciais, através de um modelo matemático, em um controle *fuzzy* utilizam-se regras lógicas no algoritmo de controle, com a intenção de descrever, em uma rotina, a experiência humana, intuição e heurística para controlar um processo (Zadeh, 1965).

No presente trabalho, o sistema *fuzzy* foi projetado com base em um modelo Mamdani, e implementado em ambiente de programação C++ *Builder*. No sistema *fuzzy*, foram utilizadas duas entradas, que são: erro e variação do erro, com relação à produção desejada para uma mistura, representadas pela fórmulas:

$$E = prod_{de} - prod \quad (7)$$

$$VE = erro - erro_{ant} \quad (8)$$

As funções de pertinência utilizadas para as variáveis de entrada foram do tipo *Bell-shaped*. Para esse tipo de função, a pertinência é dada pela seguinte equação:

$$\mu_A(x) = \frac{1}{1 + \left| \frac{x - c_f}{a_f} \right|^{2b_f}} \quad (9)$$

onde a_f , b_f e c_f são os parâmetros que ajustam a abertura, a inclinação e o centro de cada função de pertinência. Para cada variável de entrada foram utilizadas cinco funções.

4. RESULTADOS

O sistema de mistura simulado foi implementado no ambiente de programação *C++ Builder*. A Figura (4) apresenta a interface desenvolvida. Nesta interface podem ser visualizados uma simplificação gráfica dos tanques utilizados na mistura, os valores dos níveis dos tanques, valores da produção em cm^3 e da concentração do composto 1 no produto final da mistura. Além disso, são apresentados alguns gráficos relativos às variáveis do processo e algumas outras informações. Entre as funcionalidades da simulação encontram-se: alteração dos *set points*, utilização/validação do sistema de inferência neural, acionamento do controlador *fuzzy*, aplicação de sinais de excitação ao sistema de misturas, entre outros.

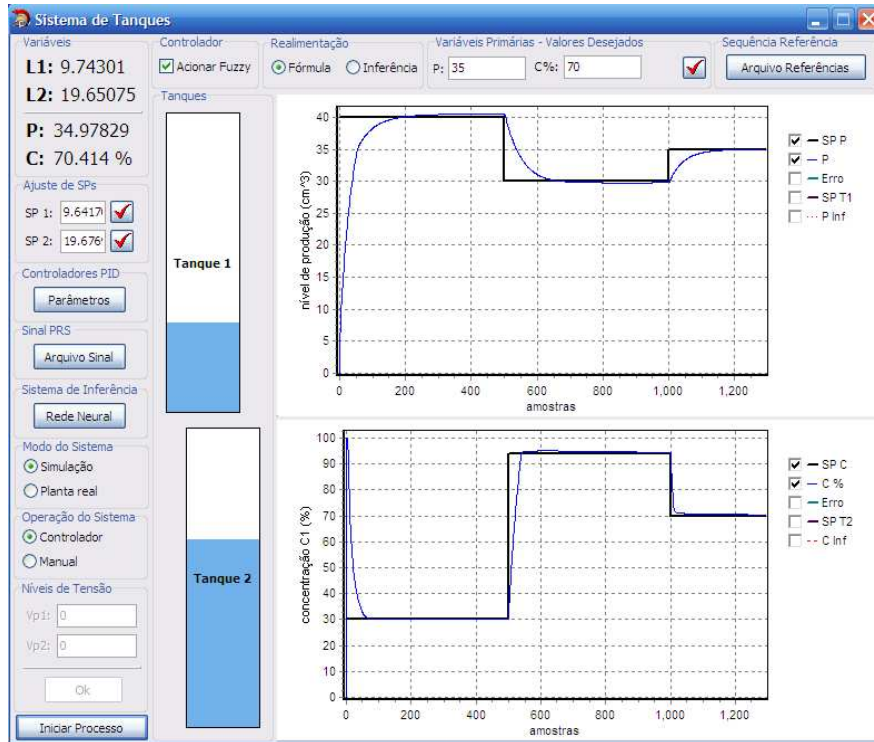


Figura 4. Interface gráfica do sistema simulado.

O primeiro passo no desenvolvimento do controlador inferencial proposto é projetar o sistema de inferência. Neste trabalho, onde o sistema de inferência é baseado em redes neurais artificiais, é necessário, inicialmente, encontrar uma rede que seja capaz de representar. Essa RNA será obtida através do processo conhecido como treinamento. Os dados utilizados no treinamento da rede neural de inferência foram obtidos estimulando o sistema simulado através da aplicação de sinais PRS aos *set points* dos controladores PIDs relacionados com as variáveis secundárias do processo (L_1 e L_2). Dessa forma, foi possível proporcionar variações nas variáveis de processo (PVs) desses controladores e, conseqüentemente, nas variáveis primárias P e C_1 que se desejam estimar. Aplicando essa metodologia, obteve-se um grupo de dados de treinamento para a rede de 3.000 amostras, incluindo medições simuladas das variáveis secundárias e primárias do sistema.

O treinamento da rede neural foi realizada no *toolbox* de redes neurais do MATLAB[®], utilizando o algoritmo de treinamento de *Levenberg-Marquardt*. Durante essa etapa, foram testadas diversas configurações de redes, alterando-se o número de neurônios por camadas e o número de regressores presente no modelo NNARX. Após o treinamento de cada configuração de rede, o sistema de inferência obtido foi utilizado junto ao sistema simulado para ser analisada a sua capacidade de generalização. A Figura (5) apresenta um dos resultados de validação da melhor rede neural encontrada. Observando essa figura, pode-se notar que o sistema de inferência projetado consegue representar as dinâmicas do processo de mistura de maneira bastante satisfatória. Mesmo nos pontos de variações mais bruscas, as variáveis primárias do processo continuam sendo bem estimadas pela rede neural de inferência.

A estrutura NNARX de melhor desempenho encontrada é formada por uma única camada oculta contendo 10 neurônios sigmoidais e 2 neurônios de saída lineares. O seu modelo é de segunda ordem, portanto, a rede neural de inferência possui 8 entradas. Foram testados modelos de outras ordens, entretanto, viu-se que o aumento da ordem não proporcionava um aumento significativo no desempenho da rede neural, em contrapartida, ocasionava um aumento considerável na complexidade da estrutura da RNA.

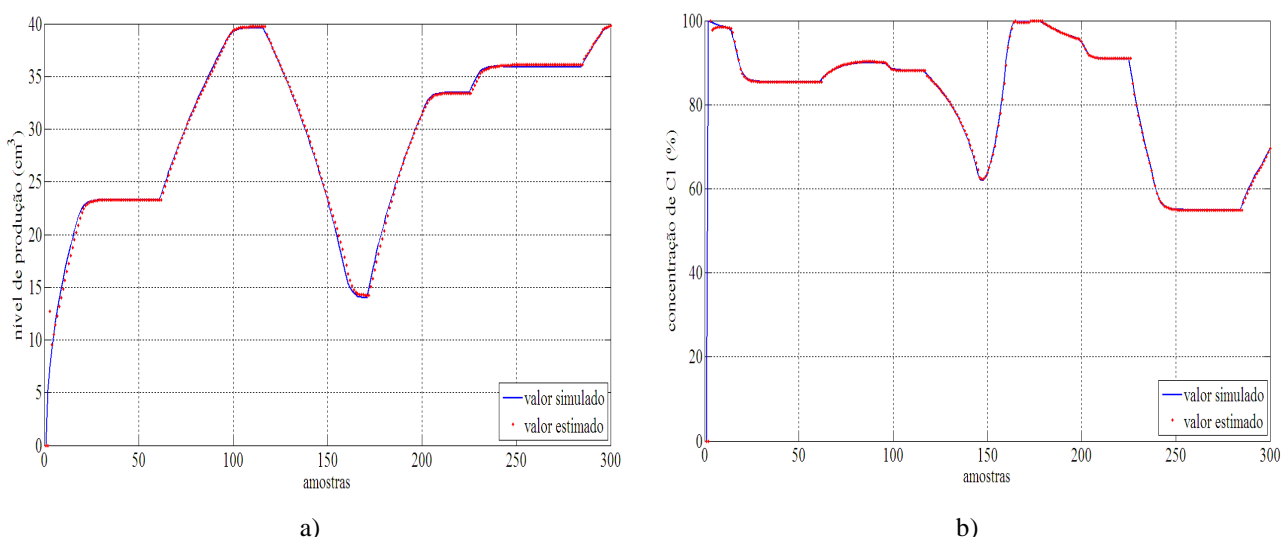


Figura 5. Validação do sistema de inferência neural. a) Estimativa do nível de produção P , b) Estimativa a concentração de C_1 realizada pelo sistema de inferência.

De acordo com os resultados apresentados na Fig. (5), pode-se afirmar que o sistema de inferência implementado fornece estimativas confiáveis das variáveis primárias do processo. Sendo assim, partiu-se para a implementação do controlador *fuzzy*. A Tabela (1) mostra os valores dos parâmetros das funções de pertinência utilizados no *fuzzy* projetado.

Tabela 1: Parâmetros das funções de pertinência.

Funções de Pertinência para o Erro					
a_f	3	3	1	3	3
b_f	0,5	0,5	0,25	0,5	0,5
c_f	-12	-6	0	6	12
Funções de Pertinência para a Variação do Erro					
a_f	0,25	0,25	0,05	0,25	0,25
b_f	0,5	0,5	0,25	0,5	0,5
c_f	-1	-0,5	0	0,5	1

Para o cálculo da variável de saída, foram utilizadas sete funções do tipo *singletons*, cujos valores são mostrados abaixo:

Tabela 2: Valores dos *Singletons*.

Funções de Pertinência para o Cálculo da Saída						
-1	-0,5	-0,25	0	0,25	0,5	1

A base de regras utilizada foi composta por sete regras, mostradas na Tab. (3). Para melhor entendimento dessa tabela, sugere-se consultar o artigo (Araújo Junior, 2007).

Tabela 3: Base de regras.

		V E				
		NG	N	Z	P	PG
E	NG	D	DP	D	AP	A
	N	D	DP	M	AP	A
	Z	D	M	M	M	A
	P	DM	D	M	A	AM
	PG	DM	D	AP	A	AM

O sistema *fuzzy* apresenta como saída valores de incremento para o nível de referência do tanque 2, caracterizando-se assim como um *fuzzy* PI (Shaw, 1999). Optou-se por utilizar valor de incremento por questões de segurança, pois, caso contrário, correria o risco de se atribuir um valor não adequado.

A partir desse nível de referência para o tanque 2 e da concentração desejada para a mistura, é calculado o nível de referência para o nível do tanque 1 por meio da Eq. (10). Sendo assim, temos um sistema MIMO (*Multiple Input – Multiple Output*), com duas entradas e duas saídas.

$$C_1 = \frac{a_1 \sqrt{L_1}}{a_2 \sqrt{L_2}} \quad (10)$$

A Figura (6) apresenta os *set points* gerados pelo sistema de controle inferencial para os níveis dos dois tanques, demonstrando, conseqüentemente, a atuação dos controladores PIDs presentes na camada de controle regulatória. A partir da análise dessa figura, pode-se observar que o controlador *fuzzy* funcionou de forma adequada. O *set point* gerado para o tanque 2 não apresentou nenhum overshoot nas mudanças de referência. Porém, o *set point* gerado para o tanque 1 apresentou *overshoots* nas duas mudanças de referência. Isso pode ser devido ao fato de que as funções de pertinência foram distribuídas simetricamente.




Figura 6. *Set Points* gerados pelo sistema de controle inferencial. a) Nível do tanque 1, b) Nível do tanque 2.

5. CONCLUSÕES

A partir dos resultados encontrados, mesmo tomando como base um sistema simulado simples, observa-se que a estratégia exposta neste trabalho pode vir a ser implementada na prática em sistemas de misturas reais, sendo possível obter bons resultados. O sistema de inferência projetado foi capaz de representar adequadamente as dinâmicas presentes no processo. A partir das estimativas das variáveis primárias obtidas pelo sistema de inferência, o controlador *fuzzy* apresentou bons resultados, mostrando que pode ser uma eficiente ferramenta em controle inferencial.

6. AGRADECIMENTOS

Os autores agradecem a PETROBRAS e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro.

7. REFERÊNCIAS

- Bittencourt, J. R., Osório F., 2002, “FuzzyF – Fuzzy Logic Framework: Uma Solução Software Livre para o Desenvolvimento, Ensino e Pesquisa de Aplicações de Inteligência Artificial Multiplataforma”. Disponível em http://www.inf.unisinos.br/~jrbitt/fuzzyf/doc/fuzzyf_wsl_2002.pdf. Último acesso em: 10/02/09.
- Bo, C., Li, J., Sun, C., Wang, Y., 2003, “The application of neural network soft sensor technology to an advanced control system of distillation operation”, Proceedings of the International Joint Conference on Neural Networks, v. 2, p. 1054-1058.

- Chella, A., Ciarlino, P., Maniscalco, U., 2006, "Neural networks as soft sensors: a comparison in a real world application", Proceedings of the International Joint Conference on Neural Networks, p. 2662-2668.
- D'Amore, R., Saotome, O., Kienitz, K. H., 1997, "Controlador nebuloso com detecção de regras ativas", III Simpósio Brasileiro de Automação Inteligente, pp. 313-318.
- Evangelista, M. A., Neves Jr, F., Arruda, L. V. R., Ramos, A. E. M., 2001, "Development of inferential distillation models using multivariate statistical methods", Proceedings of the 40th IEEE Conference on Decision and Control, v. 4, p. 3722-3727.
- Fortuna, L., Graziani, Rizzo, A., Xibilia, M., 2007a, "Soft sensors for monitoring and control of industrial processes", Springer-Verlag, New York, EUA.
- Fortuna, L., Giannone, P., Graziani, S., Xibilia, M. G., 2007b, "Virtual instruments based on stacked neural networks to improve product quality monitoring in a refinery", Proceedings of the IEEE Transactions on Instrumentation and Measurement, v.56,p.95-101.
- Garcia, C., 1997, "Modelagem e simulação de processos industriais e de sistemas eletromecânicos", Editora da Universidade de São Paulo.
- Joseph, B., 1999, "A tutorial on inferential control and its applications", Proceedings of the American Control Conference, v. 5, p. 3106-3118.
- Araújo Júnior., J. M., 2007, "Técnicas de inteligência artificial para a geração dinâmica de *set points* para uma coluna de destilação", Dissertação de Mestrado, Universidade Federal do Rio Grande do Norte, UFRN.
- Klir, G. J., Folger, T. A., 1998, "Fuzzy Sets, Uncertainty, and Informations", Prentice Hall, Englewood Cliffs - New Jersey, EUA.
- Linhares, L. L. S., Rebouças, D. L., Araújo, F. M. U., Maitelli, A. L., 2008, "Sistema de inferência baseado em redes neurais artificiais aplicado em plantas de processamento de gás natural", XVII Congresso Brasileiro de Automática, Juiz de Fora, MG.
- Nørgaard, M., Ravn, O., Poulsen, N., Hansen, L., 2001, "Neural networks for modelling and control of dynamic systems", Springer-Verlag London Limited. London, England.
- Quanser Corporation, 1998, "Coupled Water Tank Experiments".
- Warne, K., Prasad, G., Rezvani, S., Maguire, L., 2004, "Statistical and computational intelligence techniques for inferential model development: a comparative evaluation and a novel proposition for fusion", Engineering Applications of Artificial Intelligence, v. 17, n.8, p.871-885.
- Zadeg, L. A., 1965, "Fuzzy sets, information and control", pp. 338 - 353.
- Zamprogna, E., Barolo, M., Seborg, D., 2005, "Optimal selection of soft sensor inputs for batch distillation columns using principal component analysis", Journal of Process Control, v. 15, n. 1, p. 39-52.

8. DIREITOS AUTORAIS

Os autores são os únicos responsáveis pelo conteúdo do material impresso incluído no seu trabalho.



VI CONGRESSO NACIONAL DE ENGENHARIA MECÂNICA
VI NATIONAL CONGRESS OF MECHANICAL ENGINEERING
18 a 21 de agosto de 2010 – Campina Grande – Paraíba - Brasil
August 18 – 21, 2010 – Campina Grande – Paraíba – Brazil

INFERENTIAL CONTROL SYSTEM APPLIED TO SET THE CONCENTRATION AND PRODUCTION OF MIXTURES

José Medeiros de Araújo Júnior, medeiros_eng@yahoo.com.br¹
Leandro Luttiane da Silva Linhares, leandroluttiane@yahoo.com.br¹
Fábio Meneghetti Ugolino de Araújo, meneghet@dca.ufrn.br¹

¹Computation and Automation Engineering Department, Technology Center, Federal University of Rio Grande do Norte, 59078-900, Natal – RN – Brazil.

***Abstract.** Plants that perform a mixture of compounds with the aim of obtaining a particular product are found in various branches of industry. The process used in this study corresponds to a simulation of a generic mixing system. It consists of two serial tanks fed by two pumps that provide two different products which when mixed form the final product of the process. To control the concentration and the production level of this product is used in this work, an inferential control system. In general, this kind of control system involves the synthesis of a controller and the design of an inferential system, the latter is responsible for estimating the process variables that are difficult to measure or presents long delays. The inferential control system proposed consists of a fuzzy controller that receives the values of the concentration and production level of the final mixture, which are provided by an inferential system based on artificial neural networks. These variables are estimated through the tanks levels. These variables are compared with their reference values. Through the resulting errors the fuzzy controller adjusts properly the set points of the level controllers (PIDs) of the process regulatory loop.*

***Keywords:** inferential control, fuzzy controller, neural networks, mixture of compounds.*