



Copyright 2004, Instituto Brasileiro de Petróleo e Gás - IBP

Este Trabalho Técnico Científico foi preparado para apresentação no 3º Congresso Brasileiro de P&D em Petróleo e Gás, a ser realizado no período de 2 a 5 de outubro de 2005, em Salvador. Este Trabalho Técnico Científico foi selecionado e/ou revisado pela Comissão Científica, para apresentação no Evento. O conteúdo do Trabalho, como apresentado, não foi revisado pelo IBP. Os organizadores não irão traduzir ou corrigir os textos recebidos. O material conforme, apresentado, não necessariamente reflete as opiniões do Instituto Brasileiro de Petróleo e Gás, Sócios e Representantes. É de conhecimento e aprovação do(s) autor(es) que este Trabalho será publicado nos Anais do 3º Congresso Brasileiro de P&D em Petróleo e Gás

IDENTIFICAÇÃO DE MODELOS INFERENCIAIS *FUZZY* PARA A ESTIMAÇÃO DE MEDIDAS DE CONCENTRAÇÃO EM PROCESSOS DE REFINO

Elaine Yassue Nagai¹, Lúcia Valéria Ramos de Arruda²

^{1,2}Centro Federal de Educação Tecnológica do Paraná (CEFET-PR)
Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial (CPGEI)
Laboratório de Automação e Sistemas de Controle Avançado (LASCA)
Av. Sete de Setembro, 3165, 80.320-901, Curitiba, Paraná
cynagai@cpgei.cefetpr.br, arruda@cpgei.cefetpr.br

Resumo – Este trabalho apresenta uma metodologia para a identificação automática de modelos *fuzzy* inferenciais baseada em técnicas de inteligência computacional, dispondo-se somente de dados de entrada e saída coletados do sistema a ser modelado. Inicialmente, as variáveis de entrada do modelo *fuzzy* são selecionadas, dentre um conjunto de variáveis secundárias, aplicando-se mapas de Kohonen, e a estrutura do modelo é selecionada com o auxílio dos quocientes de Lipschitz. Um algoritmo de agrupamento *fuzzy* é aplicado aos dados amostrados de forma a gerar um modelo *fuzzy* inicial, com uma base de regras superestimada. Na fase final de identificação, as funções de pertinência similares são agrupadas, causando uma provável diminuição no tamanho da base de regras. Numa aplicação inicial, esta metodologia é empregada na construção de *soft sensors* para a inferência da composição do produto de topo de uma coluna de destilação binária.

Palavras-Chave: coluna de destilação, estimadores, modelagem *fuzzy*, redes neurais, *soft sensing*

Abstract – This paper presents an approach to build a soft sensor based on computational intelligence techniques. The goal is to identify fuzzy models from numerical data. First of all, the fuzzy model input variables are selected from the secondary variables set by applying Kohonen maps. Then, the Lipschitz quotients are used to select the lag structure of the fuzzy model. A fuzzy clustering algorithm is applied to find an initial rule base is simplified by merging the similar membership functions. The validity of the proposed identification method is demonstrated by the development of a soft sensor to infer the top composition of a distillation column.

Keywords: distillation columns, estimators, fuzzy modeling, neural networks, soft sensing

1. Introdução

Modelos inferenciais, ou *soft sensors*, apresentam-se como uma abordagem alternativa para a estimação de variáveis do processo nos casos onde sensores físicos não são disponíveis, devido ao seu alto custo de instalação ou devido a limitações técnicas. Considerando-se que, na maioria dos casos, processos químicos apresentam alta complexidade e comportamento não-linear, a modelagem destes processos mostra-se complexa quando são empregadas abordagens teóricas baseadas em filtro de Kalman ou outras técnicas clássicas de estimação (Zambroga et al., 2005; Lant et al., 1991). Na tentativa de superar tais dificuldades, abordagens alternativas baseadas em técnicas de inteligência computacional têm sido recentemente propostas (Qin, 1996; Rallo et al., 2002; Fabro, 2003), nas quais foram relatadas aplicações bem sucedidas de redes neurais e mínimos quadrados parciais no desenvolvimento de modelos inferenciais para diferentes processos.

Neste contexto, este trabalho propõe uma metodologia para a identificação de modelos *fuzzy* inferenciais que possam ser utilizados na construção de *soft sensors* para processos da indústria petroquímica. Esta metodologia é composta por três etapas. A primeira etapa corresponde à identificação da estrutura do modelo *fuzzy*, onde as variáveis de entrada são selecionadas, aplicando-se mapas de Kohonen, e para selecionar a ordem do modelo *fuzzy* são empregados os quocientes de Lipschitz. Após esta fase inicial, o algoritmo de agrupamento *fuzzy c-means* (FCM) é aplicado no espaço de entrada e saída para encontrar uma base de regras capaz de modelar a interação entre as variáveis do processo. Finalizando, o modelo inicial gerado na fase anterior passa por um processo de simplificação, onde as funções de pertinência similares, que descrevem o domínio de cada variável, são agrupadas com o objetivo de diminuir a complexidade e a carga computacional e, conseqüentemente, aumentar a interpretabilidade do modelo final, tornando-o mais simples e conciso.

Este trabalho está organizado como segue. A seção 2 detalha teoricamente cada procedimento que compõe a metodologia proposta. A seção 3 apresenta os resultados de simulação obtidos com a aplicação do *soft sensor* desenvolvido para inferir a composição do produto de topo de uma coluna de destilação binária, e concluindo o trabalho, a seção 4 apresenta as considerações finais.

2. Procedimento de Identificação

A metodologia proposta neste trabalho preocupa-se em identificar modelos *fuzzy* lingüísticos (Mamdani, 1977) para um sistema *MISO* (*multi-input single-output*). O módulo de inferência *fuzzy* utiliza o Método de Inferência de Zadeh e a saída numérica y^* é obtida através do método de defuzificação Centro de Área (COA – *Center of Area*) (Lee, 1990). A primeira fase do método proposto para a identificação de modelos *fuzzy* preocupa-se com a seleção do conjunto apropriado de entrada e com a determinação da estrutura do modelo (seleção do número de atrasos utilizados para as variáveis de entradas e saída). Estes dois problemas não são independentes, porém, nesta metodologia, eles são tratados de forma independente, através de dois procedimentos distintos, como descritos a seguir.

2.1. Seleção das Variáveis de Entrada

Neste trabalho a técnica proposta por Rallo et al. (2002) é adaptada para selecionar o subconjunto apropriado de variáveis secundárias para compor o conjunto de entrada do modelo *fuzzy* inferencial. O objetivo é encontrar o subconjunto mais adequado de variáveis secundárias que contenha a maioria das informações relevantes sobre o processo a ser modelado. Inicialmente, os subconjuntos de variáveis secundárias são especificados como segue. Primeiramente, calcula-se o coeficiente de correlação entre cada variável secundária e a variável de saída. As variáveis secundárias são ordenadas, de forma crescente, conforme os respectivos valores absolutos de coeficiente de correlação, criando o conjunto S de variáveis secundárias ordenadas. Seja p o número de variáveis secundárias. Os p subconjuntos são construídos de acordo com a seqüência de variáveis em S , ou seja, o primeiro subconjunto é composto pela primeira variável secundária em S e a variáveis de saída; e assim por diante. Então, um mapa de Kohonen é construído para cada subconjunto e a qualidade de cada mapa é calculada através da medida de dissimilaridade entre dois mapas distintos L_q e L_r (Kaski e Lagus, 1996), definida através da Equação 1 e Equação 2.

$$D(L_q, L_r) = E \left[\frac{\|d_{L_q}(x) - d_{L_r}(x)\|}{d_{L_q}(x) + d_{L_r}(x)} \right], \quad (1)$$

$$d(x) = \|x(t) - w_{bmu1(x)}(t)\| \sum_{i=p_{bmu1}}^{p_{bmu2}-1} \|w_i(t) - w_{i+1}(t)\|. \quad (2)$$

A medida de dissimilaridade informa sobre a relevância de cada combinação de variáveis secundárias em relação a variável de saída (Rallo et al., 2002), onde E é a esperança matemática; p_{bmu1} é a posição da primeira *bmu* (*best map unit* – melhor unidade do mapa); p_{bmu2} é a posição da segunda melhor *bmu*; e $d(x)$ é a distância de x até a segunda *bmu*, denotada por $w_{bmu2}(t)$, iniciando-se da primeira *bmu*, denotada por $w_{bmu1}(t)$.

A distância $d(x)$ combina uma indicação da continuidade do mapeamento a partir do conjunto de dados para a estrutura do mapa com uma medida de precisão do mapa na representação do conjunto de dados (Kaski e Lagus, 1996).

O menor valor de dissimilaridade média calculado com a Equação 1 para qualquer subconjunto de variáveis secundárias indica a similaridade na qualidade e na quantidade da informação representada pelos mapas.

2.2. Seleção da Estrutura do Modelo *Fuzzy*

O método proposto por He e Asada (1993) é aplicado para selecionar a ordem do modelo *fuzzy*. Este método utiliza os quocientes de Lipschitz, calculados a partir do conjunto de dados amostrados do processo, $\{x(t), y(t)\}$, $t=1, \dots, N_d$, onde $x(t)$ é o vetor contendo todas as n variáveis de entrada (selecionadas anteriormente) e $y(t)$ é a saída do modelo *fuzzy*, e do vetor de regressores definido pela Equação 3 e Equação 4:

$$\varphi(t) = [y(t-1), \dots, y(t-lag_y), x(t-1), \dots, x(t-lag_x)]^T, \quad (3)$$

$$Z^{N_d} = \{\{\varphi(t), y(t), \quad t=1, \dots, N_d\}\}, \quad (4)$$

onde lag_y é o atraso da variável de saída; lag_x é o atraso da variável de entrada; e Z^{N_d} é o conjunto de N_d pares de entrada e saída. Portanto, para todas as combinações de pares de entrada-saída, o quociente de Lipschitz é calculado como na Equação 5. O procedimento para a seleção da ordem do modelo *fuzzy* é apresentado na Figura 1 (He e Asada, 1993).

$$q_{i,j} = \frac{\|y(t_i) - y(t_j)\|}{\|\varphi(t_i) - \varphi(t_j)\|}, \quad i \neq j. \quad (5)$$

Passo 1: Para uma dada escolha de atraso, determinar os quocientes de Lipschitz para todas as combinações de pares de entrada e saída.

Passo 2: Selecionar os r maiores quocientes, $r = 0.01N_d \approx 0.02N_d$. Os maiores quocientes ocorrem, em geral, quando as diferenças $\varphi(t_i) - \varphi(t_j)$ são pequenas.

Passo 3: Avaliar o seguinte critério (Equação 6):

$$\bar{q}^{(z)} = \left(\prod_{i=1}^r \sqrt{n} q^{(z)}(t) \right)^{\frac{1}{r}}, \quad \text{onde } q^{(z)} \text{ é o quociente referente ao atraso } z. \quad (6)$$

Passo 4: Repetir os cálculos para um determinado número de atrasos distintos.

Passo 5: Plotar o critério como uma função do atraso e selecionar o número ótimo de regressores como o “*knee-point*” da curva.

Figura 1. Algoritmo de seleção da estrutura do modelo *fuzzy*.

2.3. Geração da Base de Regras Inicial

Nesta fase, o algoritmo de agrupamento *fuzzy c-means* (FCM) (Bezdek, 1987) é aplicado no espaço de entrada e saída e as amostras do conjunto de dados são classificadas em ncr clusters de modo a gerar uma base de regras superestimada, onde cada cluster corresponde a uma regra. Um valor superdimensionado para o tamanho da base de regras inicial (ncr) é empregado como uma tentativa de cobrir todas as regiões importantes do espaço de entrada e saída, tornando o resultado do agrupamento menos dependente da partição inicial do domínio das variáveis (Nagai, 2004).

As funções de pertinência referentes aos conjuntos *fuzzy* das regras são obtidas a partir da projeção *fuzzy* dos clusters no domínio de cada variável (de entrada e saída). A Figura 2 ilustra a projeção dos clusters nos domínios das variáveis x e y , e a Figura 3 demonstra a base de regras gerada a partir do resultado da projeção dos clusters.




Figura 2. Projeção dos clusters.

C_1 : Se x é A_1 Então y é B_1
 C_2 : Se x é A_2 Então y é B_2
 C_3 : Se x é A_3 Então y é B_3

Figura 3. Base de regras obtida.

Este procedimento gera os pontos discretos das funções de pertinência em cada domínio, que podem ser aproximados por uma função de pertinência paramétrica. Neste trabalho foi selecionada a função de pertinência gaussiana para esta finalidade. Neste caso, os parâmetros das funções de pertinência podem ser facilmente encontrados a partir dos conjuntos *fuzzy* discretos. Para cada conjunto *fuzzy*, o elemento com o maior grau de função de pertinência é o centro da função gaussiana e o desvio padrão é calculado através dos valores discretos que descreve o conjunto *fuzzy*.

2.4. Simplificação da Base de Regras Inicial

A transparência de um modelo *fuzzy* é um dos aspectos que distinguem a modelagem *fuzzy* de métodos de modelagem tipo caixa-preta. Tal aspecto permite a interpretação e análise do modelo obtido (Babuska et al., 1998). Porém essa transparência não é alcançada facilmente, principalmente quando o modelo *fuzzy* é identificado automaticamente através de amostras de dados, como é o caso desta implementação.

Nesta metodologia, o número de funções de pertinência de cada variável não é pré-determinado, sendo possível a existência de funções de pertinência similares. Funções de pertinência similares são funções altamente sobrepostas, que descrevem quase a mesma região no domínio da variável a qual esses conjuntos pertencem (como os conjuntos A1 e A3 na Figura 2), fazendo com que o modelo utilize mais conjuntos *fuzzy* do que o necessário (Nagai, 2004).

Desta forma, as funções de pertinência similares são agrupadas, ou seja, os parâmetros dessas funções são substituídos por novos parâmetros, tal que o novo valor de centro é a média dos valores de centro das funções de pertinência similares, e o novo valor de desvio padrão é o maior valor de desvio padrão dentre as funções similares. Após este procedimento, as regras são atualizadas com as novas funções de pertinência. Este procedimento de simplificação preocupa-se em agrupar as funções de pertinência que descrevem o mesmo local no domínio de uma determinada variável. A diminuição do tamanho da base de regras é uma consequência dessa simplificação. A melhoria da estrutura realizada nesta fase desempenha um importante papel na identificação de modelos *fuzzy*, pois ela aumenta a interpretabilidade e transparência do modelo, duas características essenciais dos sistemas *fuzzy* (Guillaume, 2001).

2.5. Tratamento de Regras Inconsistentes

Considerando-se que o número de regras geradas pelo algoritmo de agrupamento é muito grande, é provável que existam regras inconsistentes, ou seja, regras que possuem o mesmo antecedente e consequentes diferentes. Além disso, a união de conjuntos *fuzzy* similares também pode causar inconsistência em regras. Para resolver esse conflito, é utilizado um procedimento descrito em Nagai (2004) baseado na medida do fator de confiança CF (Quinlan, 1987) de uma regra. Finalizando, a Figura 4 ilustra a seqüência dos procedimentos que compõem a metodologia proposta para a identificação de modelos *fuzzy* inferenciais.

-
- Passo 1:** Selecionar o conjunto de entrada do modelo *fuzzy* a partir do conjunto de variáveis secundárias disponíveis, como descrito na Seção 2.1;
- Passo 2:** Selecionar a estrutura do modelo como descreve o algoritmo da Figura 2;
- Passo 3:** Estabelecer os conjuntos de treinamento e teste, o tamanho da base de regras inicial *ncr*, o parâmetro *m* do algoritmo *FCM*, e o erro aceitável ξ ;
- Passo 4:** Gerar a base de regras inicial conforme descreve a Seção 2.3;
- Passo 5:** Simplificar a base de regras inicial, agrupando as funções de pertinência similares, como descrito na Seção 2.4, e atualizar a base de regras com as novas funções de pertinência;
- Passo 6:** Verificar a existência de regras inconsistentes na base de regras (Seção 2.5), calcular o CF para cada regra inconsistente. A regra com o maior valor de CF é mantida e as demais são removidas da base de regras;
- Passo 7:** Calcular o erro ao aplicar o conjunto de teste ao modelo *fuzzy*. Se o erro é maior do que ξ , então retornar ao passo 4, caso contrário finalizar o procedimento de identificação.
-

Figura 4. Sumário da metodologia de identificação.

3. Resultados Experimentais

Esta seção apresenta os resultados de simulação obtidos durante a aplicação da metodologia proposta para a identificação de modelos *fuzzy* inferenciais. O processo considerado é uma coluna de destilação binária e o objetivo é obter um modelo *fuzzy* inferencial para estimar a composição do produto de topo dessa coluna durante a sua fase de inicialização. As amostras de dados foram obtidas de Fabro (2003), onde uma coluna de destilação binária foi modelada com o auxílio da ferramenta computacional *HYSYS*¹, como ilustra a Figura 5. A coluna possui 20 pratos e apresenta as características de funcionamento em regime estacionário como descrito na Figura 6 (Neves-Jr e Aguilar-Martin, 1999).

O perfil de temperatura da coluna é determinado por quatro sensores posicionados nos pratos (dois acima do ponto de alimentação, nos pratos 9 e 13, e dois abaixo, nos pratos 16 e 18). Quando as temperaturas lidas nos pratos aproximam-se do perfil definido no projeto da coluna para o funcionamento em regime estacionário, o processo de inicialização chega ao final (Fabro, 2003). Nesta situação, a composição de destilado (metanol) retirado da coluna apresenta concentração maior que 99,9%. Apesar das informações de concentração estarem disponíveis diretamente no simulador *HYSYS*[®], isto nem sempre é possível em ambientes industriais, onde é comum o uso de testes laboratoriais para a determinação da composição do produto (Qin, 1996). O conhecimento sobre a medida das composições dos produtos é necessário durante o procedimento de inicialização, pois elas demarcam o momento onde é possível iniciar a retirada de fluidos da coluna.

¹ HYSYS 3.0, HYPROTECH Ltd.




Figura 5. Coluna de destilação binária.

- Composição de alimentação: 50% de água e 50% de metanol;
- Temperatura de alimentação: 75,9°C;
- Vazão molar de alimentação: 236kmol/h, inserido na coluna na altura do prato 14;
- Concentração do produto de topo (destilado): ao menos 99,9% de metanol em regime;
- Vazão do produto de topo (destilado); 85kmol/h;
- Concentração do produto de base (resíduo): ao menos 99,9% de água;
- Vazão do produto de base (resíduo): 151kmol/h;
- Refluxo do condensador para a coluna: 247kmol/h;
- Pressão no topo da coluna: 101,3kPa;
- Perfil de temperatura (temperatura medida nos pratos):
 - o Prato 9: 67,54°C;
 - o Prato 13: 86,41°C;
 - o Prato 16: 101,3°C;
 - o Prato 18: 102,3°C;

Figura 6. Características de funcionamento da coluna.

Este artigo se propõe a construir um *soft sensor fuzzy* para inferir a composição do produto de topo (metanol) durante o procedimento de inicialização da coluna de destilação. Segundo Fabro (2003), no início do procedimento de inicialização, enquanto a coluna está sendo aquecida, o conhecimento desta composição não é necessário. Com o avanço do processo de inicialização, a estimativa dessa composição torna-se importante, principalmente quando esta se aproxima do nível de pureza desejado para o início da retirada do produto de topo. Desta forma, a faixa de operação considerada foi entre 90% e 99,9% de pureza para estimar a composição do metanol. As variáveis secundárias disponíveis são descritas na Tabela 1. A Tabela 2 apresenta as variáveis de entrada selecionadas ($u_1, \dots, u_7$), e o número de funções de pertinência para cada variável do modelo (inclusive para a variável de saída) obtidas após o procedimento de simplificação do modelo *fuzzy*.

Tabela 1. Descrição das variáveis secundárias.

variável	descrição
<i>feed1_pv</i>	vazão molar de alimentação
<i>reflux_pv</i>	refluxo do condensador para a coluna
<i>pv_press</i>	pressão no topo da coluna
<i>bottom_pv</i>	nível líquido do reboiler
<i>top_pv</i>	nível líquido do condensador
<i>tray9</i>	temperatura do prato 9
<i>tray13</i>	temperatura do prato 13
<i>tray16</i>	temperatura do prato 16
<i>tray18</i>	temperatura do prato 18
<i>cond_flow</i>	vazão para o condensador
<i>top_flow</i>	vazão do produto de topo (destilado)
<i>bottom_flow</i>	vazão do produto de base (resíduo)

Tabela 2. Variáveis de entrada selecionadas.

#	variáveis	nº conj. fuzzy
u_1	<i>feed1_pv</i>	8
u_2	<i>top_pv</i>	8
u_3	<i>tray9</i>	9
u_4	<i>tray13</i>	10
u_5	<i>tray16</i>	8
u_6	<i>tray18</i>	7
u_7	<i>cond_flow</i>	8
u_7	composição do metanol	9
y	composição do metanol	11

Como descrito na Tabela 2 foram selecionadas sete variáveis de entrada, e considerando-se um modelo preditivo com realimentação da saída com o atraso selecionado ($lag_y = lag_u = 2$), o espaço de entrada do modelo *fuzzy* é composto por 15 variáveis. Nesta implementação, de modo a evitar um esforço computacional elevado, incrementou-se simultaneamente o número de atrasos para as variáveis de entrada e saída. O valor tamanho da base de regras inicial (*ncr*) utilizado foi 100, e após o procedimento de simplificação, este número foi reduzido para 45 regras.




Figura 7 Inferência da composição do produto no topo da coluna.

Tabela 3. Índices de desempenho do modelo *fuzzy* inferencial.

	treinamento	teste	total
<i>mse</i>	0,0482	0,0505	0,0494
<i>nrmse (%)</i>	0,2287	0,2348	0,2318

A Tabela 3 apresenta os índices de desempenho do modelo, onde foram empregados dois índices de desempenho, o *mse* (*mean-square error* – média do erro quadrático) e o *nrmse* (*normalized root mean-square error* – erro normalizado) (Nagai, 2004). A Figura 7 apresenta a comparação entre a composição do produto de topo inferida pelo modelo inferencial ou *soft sensor* (linha pontilhada) e a composição esperada (linha contínua). Através da Figura 7 observa-se que a curva da saída inferida através do modelo *fuzzy* acompanha a tendência da curva esperada, porém é possível notar que o modelo *fuzzy* apresenta deficiências em inferir as saídas próximas aos limites do universo de discurso (neste caso valores próximos de 90% e 99% de concentração de metanol). Isto se deve ao fato das regras e funções de pertinência serem geradas a partir do algoritmo de agrupamento *FCM*, que tende a enfatizar os pares de dados próximos aos centros dos clusters e, portanto, os dados longe desses centros não são tratados devidamente.

4. Considerações Finais

Este trabalho propõe uma metodologia para a identificação de modelos *fuzzy* inferenciais para a construção de *soft sensors*. Esta metodologia é composta por três fases. Inicialmente as variáveis de entrada são selecionadas aplicando-se mapas de Kohonen e os quocientes de Lipschitz são utilizados para selecionar a ordem do modelo. Então o algoritmo *FCM* é aplicado no espaço de entrada e saída de modo a encontrar o modelo *fuzzy* inicial. Na terceira fase, as funções de pertinência similares são agrupadas como o intuito de eliminar a redundância na descrição do domínio de cada variável do modelo. Esta simplificação pode causar a redução do tamanho da base de regras, aumentando a interpretabilidade e transparência do modelo obtido. A metodologia proposta foi utilizada na construção de um *soft sensor* para a estimação da medida de composição do produto de topo de uma coluna de destilação binária durante a sua fase de inicialização. Os resultados apresentados indicam que esta metodologia foi capaz de gerar um estimador de composição cujo desempenho pode ser melhorado com o uso de técnicas de refinamento do modelo *fuzzy* inferencial, tais como um método para a sintonia dos parâmetros das funções de pertinência e um método para a avaliação da relevância de cada regra do modelo de modo a reduzir o tamanho da base de regras.

5. Agradecimentos

Este trabalho conta com o apoio financeiro da Agência Nacional do Petróleo - ANP - e da Financiadora de Estudos e Projetos - FINEP - por meio do Programa de Recursos Humanos da ANP para o Setor Petróleo e Gás - PRH-ANP/MCT (PRH10-CEFET-PR).

6. Referências

- BABUSKA, R., KAYMAK, U., VAN NAUTA, H. R., SETNES, M. Similarity measures in *fuzzy* rule base simplification. *IEEE Transactions on Systems, Man, and Cybernetics – Part B*, v. 28, n. 3, p. 376-386, 1998.
- BEZDEK, J. C. *Pattern recognition with fuzzy objective function algorithms*, Plenum Press, 1987.
- FABRO, J. A. *Uma abordagem neuro-nebulosa para controle preditivo de processos multi-estágios*, Tese de Doutorado, CPGEI/CEFET-PR, Curitiba-PR-Brasil, 2003.
- GUILLAUME, S. Designing *fuzzy* inference systems from data: an interpretability-oriented review. *IEEE Transactions on Fuzzy Systems*, v. 09, n. 03, p. 426-443, 2001.
- HE, X., ASADA, H. A new method for identifying orders of input-output models for nonlinear dynamical systems. *In Proc. Of the American Control Conference*, p. 2520-2523.
- KASKI, S., LAGUS, K. Comparing self-organizing maps. *In Proc. of ICANN'96*, 1996.
- LANT, P. A., MONTAGUE, G. A., MORRIS, A. J., THAM, M. T. Soft-sensors for process estimation and inferential control. *Journal of Process Control*, v. 01, p. 3-14, 1991.
- LEE, C. C. *Fuzzy logic in control systems: fuzzy logic controller – part I and II. IEEE Transactions on Systems, Man, and Cybernetics*, v. 20, p. 404-418, 1990.
- MAMDANI, E. H. Application of *fuzzy* logic to approximative reasoning using linguistic systems. *Fuzzy Sets and Systems*, v. 26, p. 1182-1191, 1977.
- NAGAI, E. Y. *Identificação de modelos fuzzy inferenciais*. Monografia de Qualificação, CPGEI/CEFET-PR, Curitiba-PR-Brasil, 2004.
- NEVES-JR, F., AGUILAR-MARTIN, J. Qualitative event-based expert supervision for transient condition monitoring. *Applied Intelligence*, v. 10, p. 197-210, 1999.
- QIN, S. J. *Neural networks for intelligent sensor and control – practical issues and some solutions*. Academic Press, cap. 8, p. 215-236.
- QUINLAN, J. R. Generating production rules from decision trees. *In Proc. Int. Joint Conf. AI*, p. 304-307, 1987.
- RALLO, R., FERRE-GINE, J. ARENAS, A., GIRALT, F. Neural virtual sensor for the inferential prediction of product quality from process variables. *Computers and Chemical Engineering*, v. 26, p. 1735-1754, 2002.
- ZAMBROGNA, E., BAROLO, M., SEBORG, D. E. Optimal selection of soft sensor inputs for batch distillation columns using principal component analysis. *Journal of Process Control*, v. 15, p. 39-52, 2005.