

UMA ESTRATÉGIA DE CONSTRUÇÃO DE UM “SOFT SENSOR” PARA INFERENCIAR A COMPOSIÇÃO DO PRODUTO DE UM PROCESSO DE DESTILAÇÃO UTILIZANDO TÉCNICA NEURO-FUZZY

Arioston A. Morais, Raphael R. C. Santos, Cristiane H. Sodr , Frede O. Carvalho and William G. Vieira

*Universidade Federal de Alagoas, Macei , Alagoas, Brazil, arjir@bol.com.br,
<http://www.ctec.ufal.br/posgraduacao/ppgeq/>*

Palavras Chave: Soft sensor, coluna de destila o, neuro-fuzzy, an lise de sensibilidade.

Resumo. Soft sensor consiste em um modelo matem tico que   utilizado para estimar vari veis de interesse em fun o de vari veis secund rias de f cil medi o. Esta t cnica surge de uma dificuldade operacional ou do alto custo de obten o da vari vel desejada. Neste trabalho   proposta uma estrat gia para constru o de um soft sensor, que envolve desde a aquisi o de dados, an lise de sensibilidade das vari veis de entrada, constru o de um modelo inferencial caixa-preta que utiliza t cnica neuro-fuzzy, at  a valida o deste modelo. A estrat gia foi desenvolvida utilizando dados de uma planta piloto de destila o, que t m como objetivo separar o metanol da  gua numa coluna com 10 bandejas. O processo de destila o mostrou-se interessante para o presente estudo, uma vez que apresenta dificuldades na obten o da composi o do produto. A estrat gia computacional constru da mostrou-se adequada e produziu bons resultados na estimativa da composi o.

1 INTRODUÇÃO

Soft sensor consiste em um modelo matemático que é utilizado para estimar variáveis de interesse em função de variáveis secundárias de fácil medição. Esta técnica surge de uma dificuldade operacional ou do alto custo de obtenção da variável desejada.

As indústrias estão utilizando cada vez mais esta ferramenta matemática, principalmente para melhorar as especificações dos produtos e para controle dos índices das emissões de compostos poluentes, Fortuna et al.(2007).

A necessidade de implantação de um soft sensor surge dos reais tipos de problemas a serem enfrentados, diversas aplicações podem ser destacadas: inferência de variáveis; detecção de falhas; previsão de desempenho; aproximação de funções não-lineares; e identificação de padrões de processos.

O soft sensor pode ser uma boa alternativa em relação ao sensor tradicional, desde que as variáveis de entrada (secundárias) possam ser medidas sem problemas e quando a simulação para a geração do modelo do sensor seja capaz de fornecer a variável desejada Lotufo e Garcia (2008).

As entradas do modelo inferencial podem ser, por exemplo, temperaturas, fluxos e pressões, também chamadas de variáveis secundárias, uma vez que estas são facilmente medidas on-line. Devido a natureza dos processos químicos e sistemas de engenharia de processo, os estados de muitas das variáveis secundárias refletem os estados de variáveis complexas, Jerbic et al. (2007).

O sistema Neuro- Fuzzy é a técnica empregada neste trabalho para construção do soft sensor, por ser o meio mais fácil de inserir conhecimento a priori dentro de um soft sensor.

1.1 Motivação para o trabalho

Devido as características inerentes e as restrições operacionais típicas em todo processo químico, as colunas de destilação apresentam algumas restrições: hidráulicas, na separação e de transferência de calor.

Pode-se dizer que a maior restrição no processo de destilação está ligada na forma de obtenção dos valores das composições dos produtos. A variável composição é uma grandeza não diretamente mensurável e sofre constantes modificações no processo.

A motivação para o trabalho surge da dificuldade de obtenção desta variável, uma vez que métodos tradicionais para medir composição, tais como a cromatografia gasosa apresenta grandes atrasos de medição, quando realizados no laboratório. Já os sistemas utilizados em linha apresentam elevados custos de aquisição e manutenção, Kano et al. (2000).

1.2 Metodologia

Neste trabalho é proposta uma estratégia para construção de um soft sensor, que envolve desde a aquisição de dados, análise de sensibilidade das variáveis de entrada, construção de um modelo inferencial caixa-preta que utiliza técnica neuro-fuzzy, até a validação deste modelo.

Na etapa de construção do modelo neuro-fuzzy do soft sensor foi necessário utilizar uma técnica de agrupamento de dados, para que algumas limitações de inferência fossem superadas.

O objetivo do trabalho é construir um soft sensor para obter on-line a composição final de metanol no topo da coluna de destilação. Este objetivo foi alcançado utilizando a metodologia descrita na Figura 1.



Figura 1: Metodologia Empregada na construção do Soft Sensor.

O modelo inferencial (soft sensor) pode ser uma boa alternativa em relação aos métodos de medição tradicionais, desde que as variáveis de entrada utilizadas apresentem confiabilidade e quando a estrutura para a geração do modelo inferencial seja capaz de fornecer a variável desejada.

2 AQUISIÇÃO DOS DADOS

Todos os dados usados para construção do soft sensor foram obtidos num modelo dinâmico de uma planta piloto, num processo contínuo de destilação binária projetado para separar a mistura metanol-água. O modelo dinâmico utilizado foi o validado por **Sodré (2001)**. O esquema da planta piloto é apresentado na Figura 2.

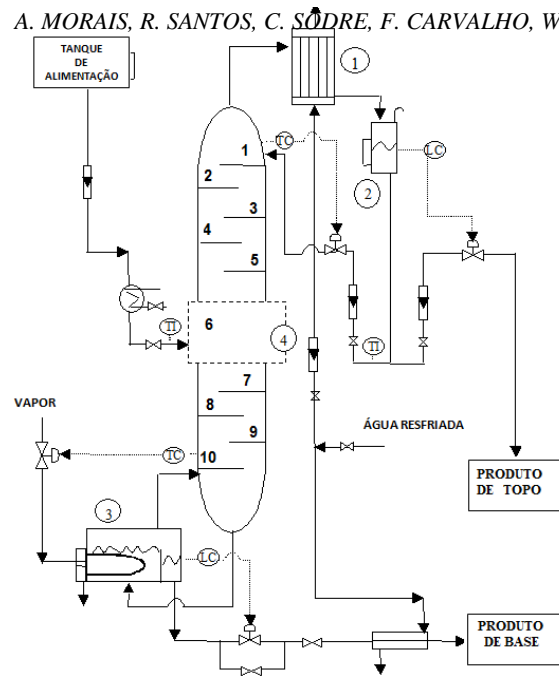


Figure 2: Esquema da Coluna de Destilação Contínua. 1 - Condensador; 2 - Tambor de Refluxo; 3 - Refervedor; 4 - Bandeja de Alimentação.

A coluna de destilação é formada por 10 bandejas, contendo dois borbulhadores cada uma, exceto a bandeja de alimentação que possui quatro borbulhadores. A coluna também é equipada com pontos de amostras de líquido, rotâmetros e termopares para controle de temperatura nas bandejas de alimentação, base e de topo. A alimentação da coluna é feita em um único ponto, na sexta bandeja. Apresenta também um condensador total, um tambor de refluxo e um refeedor parcial. A coluna possui isolamento térmico.

2.1 Modelo do Processo

O modelo dinâmico usado para gerar os dados e treinar a rede neuro-fuzzy foi obtido de tal forma que o balanço componente foi resolvido para cada bandeja, todas as equações do modelo foram obtidas em Sodr  (2001).

O balanço de energia do sistema foi representado por um modelo de equações, seguindo a configuração da Figura 3.

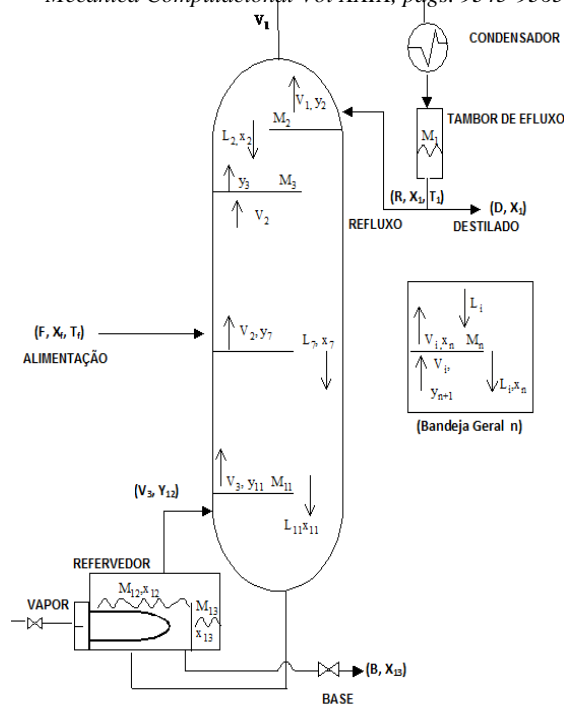


Figura 3: Esquema no qual foram baseadas as equações.

Foram usadas ainda, as relações de equilíbrio líquido-vapor e a fórmula de Francis para descrever o retido de líquido no retervedor (M_{12}) e o retido de líquido em cada bandeja (M_n).

A coluna tem dez bandejas reais, uma eficiência de Murphree de 85% em cada estágio. A corrente de alimentação é feita em um único ponto com uma mistura metanol e água, com a corrente líquida (FL) de alimentação em seu ponto de bolha, com isso não temos fluxo de vapor na alimentação (FV).

Algumas considerações foram feitas durante a modelagem da coluna: pressão constante, fluxo molar constante, retido de vapor desprezado, uma dinâmica de fluxo de vapor rápida e um equilíbrio líquido-vapor não-linear. Este modelo foi desenvolvido em linguagem Fortran® e validado com dados reais da planta piloto.

Para efeito nesse estudo e assim avaliar o comportamento da coluna em diferentes condições de operação, foram introduzidas perturbações no sistema. As seguintes variáveis foram perturbadas: Vazão de Refluxo (R) e Quantidade de Calor do Retervedor (Q_R), que é controlada pelo fluxo de vapor que entra no retervedor (V_3).

As perturbações na coluna foram limitadas às condições operacionais da planta piloto. Dois casos foram estudados: no primeiro caso foi feita uma perturbação de (+) 20% em R esperando atingir um novo estado estacionário, logo em seguida foi feita uma nova perturbação de (-) 20% em R, trazendo a coluna de volta as suas condições iniciais; no segundo caso foi feita uma perturbação de (+) 17 % em Q_R .

3 SELEÇÃO DE VARIÁVEIS

O sucesso ou não do modelo inferencial depende diretamente da etapa de seleção de variáveis, já que esta garante a confiabilidade e a validação do mesmo.

Em estruturas fenomenológicas, essa etapa está associada à seleção de modelos, pois esse é quem vai determinar quais variáveis serão utilizadas. Já em sistemas baseados em análises multivariáveis, faz-se uma análise de forma sistêmica de quais são as variáveis que deverão compor a entrada do modelo, de forma que ele represente o mais fielmente possível seus dados, Facchin (2005).

Em estruturas caixa-preta, como é o caso da rede neuro-fuzzy aplicada neste trabalho, segundo Diehl et al. (2009) e Conz (2005), entre os métodos de seleções de variáveis destacam-se os de análises combinatórias (Métodos Exaustivos), análises de sensibilidade, métodos evolutivos (*Forward Selection* (FS), *Stepwise Regression* (SR), etc) e métodos de busca aleatória (o mais usado entre eles é Algoritmo Genético (AG)).

Neste trabalho foi utilizada a técnica de seleção de variáveis secundárias por meio da análise de sensibilidade. Esta técnica fornece informações sobre as respostas do processo frente às modificações em variáveis manipuladas, Secchi et al. (2006).

3.1 Análise de Sensibilidade

Segundo Aguirre (2004), ao se buscar um modelo matemático que relacione dinamicamente duas variáveis de um sistema, parte-se do pressuposto de que há uma correlação significativa entre estas variáveis que justifique o modelo. Com isso, intuitivamente a função de covariância cruzada (FCC), Equação 1, apresenta-se como uma ferramenta capaz de determinar se há uma correlação significativa entre duas variáveis candidatas a compor um modelo.

$$Cov(x, y) = \frac{1}{N} \sum_{k=1}^N [(x(k) - \bar{x}) \cdot (y(k - \xi) - \bar{y})] \quad (1)$$

Onde: N é número de elementos (vetores de mesmo tamanho x, y);

X e Y são respectivamente os vetores de entrada e saída;

\bar{x} e \bar{y} são as médias de x e y ;

ξ é a defasagem temporal (número de atrasos analisados para o sinal).

Este método foi empregado em Zanata (2005) e Cruz (1998), onde foram calculadas as funções de covariância cruzada, também usada por Komulainen et al. (2004), em cada uma das supostas entradas e saídas, assim verificando quais das temperaturas apresentavam alta covariância.

Esta relação pode ser entendida, por exemplo, no tratamento de qual temperatura será utilizada no modelo de inferência de composição, evitando o uso redundante de todas as temperaturas dos pratos da coluna. Mejdell e Skogestad (1991 a, b) utilizaram as temperaturas para compor a entrada do modelo inferencial. Zambrogna et al. (2005) e Kano et al. (2000), selecionaram apenas as 5 bandejas cujas temperaturas apresentaram maior correlação com a composição inferida.

3.2 Descrição das Etapas Para o Estudo de Sensibilidade

A primeira etapa consiste em descrever as possíveis variáveis de entrada e a saída do soft sensor; a segunda etapa consiste em selecionar as variáveis de entrada e verificar se elas apresentam alta correlação com a composição do produto.

3.2.1-Primeira Etapa: As variáveis de entrada de um analisador virtual podem ser classificadas como: a) Variáveis Manipuladas que são aquelas que podem sofrer uma perturbação para levar a planta a diferentes condições de operação, exemplo a vazão de refluxo (R); b) Variáveis Não-Diretamente Manipuladas são aquelas que geralmente não podem ser medidas facilmente. No entanto, quando as variáveis manipuladas são perturbadas (Vazão de Refluxo, Vazão de Líquido, etc.), as variáveis não-diretamente manipuladas são sensíveis a esta excitação.

A temperatura em cada estágio é uma variável não diretamente manipulável, sofrendo alterações quando uma variável manipulada é perturbada e influi diretamente nas composições finais do processo de destilação.

Nesse estudo foram selecionadas as seguintes variáveis manipuladas para entrada do modelo inferencial: Fluxo de líquido (F_L) na alimentação, Vazão de Refluxo (R), composição de alimentação (X_f) e Calor do Refervedor (Q_R). O controle de Q_R foi feito pelo fluxo de vapor que entra no refervedor (V_3).

A composição dos produtos é sensível à variação de fluxo de líquido (F_L) e vapor (F_V) na alimentação, já que essas diminuem ou aumentam a eficiência de separação. Neste trabalho não foi utilizado a vazão de vapor (F_V), devido ao fato da alimentação da coluna ser feita só por líquido em seu ponto de bolha, assim como também foi descartada a temperatura de alimentação (T_f) que para o estudo apresentava pouca variação. Outra variável que tem relação direta na composição de destilado é a composição de alimentação (X_f), que também será utilizada.

As variáveis não-diretamente manipuladas escolhidas para o estudo de sensibilidade foram às temperaturas de todos os estágios da coluna numeradas $T_1, T_2, T_3, \dots, T_{10}$, e a temperatura do refervedor, totalizando 11 temperaturas no sistema. Todas estas variáveis selecionadas serão testadas para verificar quais são as mais sensíveis na composição.

Outras variáveis não diretamente manipuláveis tais como a Pressão interna dos estágios, poderiam ser selecionadas, no entanto, o modelo considera a pressão constante no sistema, logo esta variável foi descartada.

A saída do modelo inferencial foi a composição do metanol do topo (X_1) da coluna.

3.2.2-Segunda Etapa: Nesta etapa foram selecionadas as variáveis secundárias, para isso foi necessário o estudo de sensibilidade, baseado nas respostas às perturbações e no tempo de amostragem.

Foi realizada uma perturbação degrau de (+) 5% ou (-) 5% nas seguintes variáveis manipuladas: fluxo de líquido (FL) na alimentação, calor do refervedor (QR), vazão de refluxo (R) e a composição de alimentação (X_f), de maneira a obter o aumento das temperaturas nos pratos, ou seja, um aumento de composição. Pode-se observar na figura 4 que a resposta à perturbação na vazão de refluxo foi a mais rápida.




Figura 4: Comportamento das variáveis com a composição do destilado.

Ainda foi necessário calcular o tempo de amostragem (**T**), que é o período entre duas amostras. A fim de que um sinal amostrado retenha algumas das características fundamentais do sinal original, é necessário que o tempo de amostragem seja suficiente curto, Aguirre (2004). Neste trabalho o cálculo do tempo de amostragem foi feito de três maneiras distintas, com base nas abordagens de Zanata (2005) e Aguirre (2004), mas apenas o método da constante de tempo que foi o que apresentou o menor valor para esta constante é que será detalhado aqui.

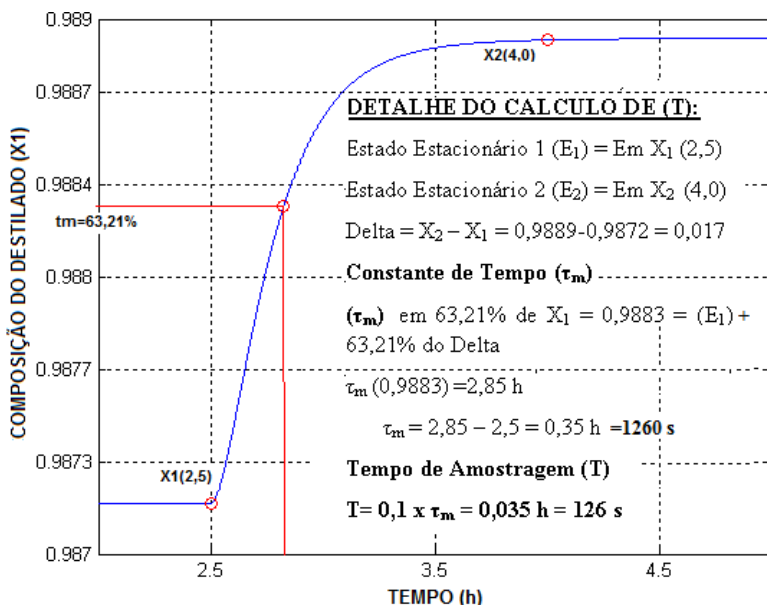


Figura 5: Detalhe do Cálculo do menor tempo de amostragem do sistema

O método da constante de tempo (t_m) consiste em perturbar o sistema (ver segunda etapa) e observar a perturbação que causa a resposta mais rápida, neste caso, a vazão de refluxo (R). Calcular a constante de tempo para essa resposta e em seguida calcular um décimo deste valor para obter o tempo de amostragem. Observando a Figura 5, pode-se verificar que a constante de tempo que corresponde a 63,21% do delta entre os estados estacionários corresponde a 0.35h, ou 1260s. Tomando-se um décimo deste tempo, obtém-se tempo de amostragem igual a 126s.

Dois outros métodos foram utilizados para calcular o tempo de amostragem: a análise da auto covariância, Aguirre (2004), obteve tempo de amostragem igual a 290s; e o método proposto por Zanata (2005), baseado em estimativa do tempo de acomodação associado com a composição do componente na fase líquida no último estágio da coluna ($n=10$) após a aplicação de um degrau, obteve-se tempo de amostragem de 360s.

Após o cálculo do tempo de amostragem considera-se também que os dados do soft sensor representem uma amplitude, em que se espera que o sensor venha operar nas situações reais. Com isso, faz-se necessário introduzir um ruído nas variáveis manipuladas perturbando o regime de operação da coluna, as perturbações introduzidas foram de (+) ou (-) 5%, e na frequência de 3 em 3 tempos de amostragem, ou seja, 378s ou 0.105h para um regime de operação da coluna de 18 h, conforme a figura 6.




Figura 6 – Perfil de temperaturas da coluna durante a excitação aleatória.

Como foi mencionado anteriormente na seção 3, faz-se necessário selecionar as entradas do modelo de inferência. Nesse estudo optou-se em utilizar a covariância cruzada, utilizando a Equação (1), para escolher quais temperaturas serviriam como

entrada do soft sensor. Como pode ser verificado no gráfico da Figura 7, as temperaturas dos primeiros estágios apresentam maior covariância e menor tempo de atraso.

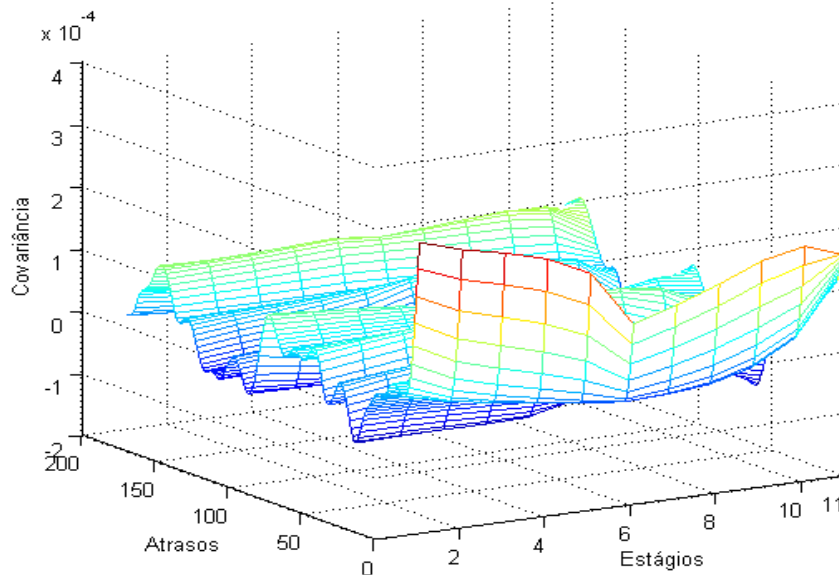


Figura 7 – Covariância cruzada das temperaturas nos estágios e a composição metanol.

Já o gráfico da Figura 8 mostra as temperaturas que apresentaram maior covariância atrasadas em até 250 períodos de amostragem.




Figura 8: Covariância cruzadas das temperaturas dos estágios mais sensíveis.

Neste trabalho foi decidido utilizar as cinco temperaturas mais sensíveis na composição, com base nos trabalhos de Kano et al (2000) e Zambrogna(2005), as cinco temperaturas mais sensíveis que foram as temperaturas dos cinco primeiros estágios da coluna T1, T2, T3, T4 e T5.

Por fim, a aquisição de dados no modelo da coluna foi feita utilizando 442 pontos referentes a 18 horas de operação da planta piloto, com isso foi coletado as 9 variáveis de entrada para treinamento e validação da rede neuro-fuzzy, que são: T1, T2, T3, T4, T5, QR, R, Xf e FL e a variável de saída X1 (Composição do metanol no topo da coluna). Estes dados foram salvos, em arquivo do Matlab®, para utilização na etapa seguinte.

5 MODELO INFERENCIAL

A maioria dos processos químicos, como é o caso da destilação, apresentam comportamento não linear proporcionando uma modelagem complexa quando são utilizadas técnicas clássicas de estimação.

Das metodologias usuais empregadas na construção do modelo inferencial (soft sensor), destacam-se os modelos caixa-branca, modelos caixa-cinza e também os modelos caixa-preta. Este último aplica técnica de sistemas inteligentes na geração do sensor, e é a ferramenta matemática mais usualmente empregada na construção de soft sensor, por não requerer um conhecimento fenomenológico do processo.

Dentre as técnicas de sistemas inteligentes mais aplicadas na construção dos sensores destacam-se a Rede Neural Artificial (RNA) e a lógica fuzzy.

O emprego de da RNA para construção de sensores se justifica pela sua habilidade de aprendizado adaptativo, suas propriedades de generalização e a capacidade de processamento paralelo. No entanto, os valores das conexões (pesos) os quais caracterizam uma RNA são difíceis de entender e explicar, conferindo pouca interpretabilidade ao modelo gerado Arruda et al. (2007).

Já os sistemas de inferência fuzzy são implementações computacionais baseadas nos conceitos da teoria de conjuntos nebulosos, nas regras Se-então nebulosas e na inferência nebulosa (Jang et al., 1997). Estes são adequados para criação de modelos a partir de um conhecimento explícito de um conjunto de dados, originário de especialistas humanos.

Recentemente surge o conceito e a aplicação de sistemas híbridos, cujo termo híbrido significa cruzamento de espécies diferentes, que utiliza duas técnicas de modelagem, que proporciona um sistema heterogêneo com características inteligentes.

A técnica híbrida mais aplicada é aquela que combina em sua arquitetura as redes neurais artificiais e a lógica fuzzy, gerando uma modelagem Neuro-Fuzzy, cuja associação das técnicas permite integrar as vantagens de cada abordagem e minimizar as deficiências de ambas.

O sistema Neuro- Fuzzy é a técnica empregada neste trabalho, por ser o meio mais fácil de inserir conhecimento a priori dentro de um soft sensor. Entretanto, um

problema pode ocorrer devido ao aumento da dimensão da entrada, isso faz com que a base de regras fuzzy promova um aumento exponencial levando a um aumento no custo computacional, na memória do sensor e na quantidade de dados necessários para treinamento do soft sensor.

Tendo em vista os problemas relacionados ao número de entrada e para garantir a viabilidade do sensor é utilizada uma técnica baseada no agrupamento de dados "Clusterização". Com essa técnica é possível que a estrutura do modelo represente a dinâmica da aplicação, tenha o menor número de parâmetros livres que representem adequadamente o sistema e contenha uma maior precisão em diferentes faixas de operação.

5.1 Agrupamento dos dados

A técnica de agrupamento de dados denominada clusterização é uma classificação não-supervisionada de dados, formando agrupamentos ou clusters.

O agrupamento de dados (data clustering) é uma técnica largamente empregada para organização, segregação e compressão de dados, também utilizada na construção de modelos (Jang et al., 1997).

Com a clusterização ocorre o particionamento de um conjunto de dados em vários grupos, de forma que a similaridade interna em um grupo seja maior que entre grupos, cuja similaridade é medida normalmente com base nos cálculos da distância entre clusters.

As técnicas freqüentemente utilizadas para a criação de agrupamentos, segundo Takahashi (2006), aplicadas na modelagem através de sistemas nebulosos ou fuzzy, são: K-means ou C-means; Fuzzy C-means clustering; Mountain clustering; e a Subtractive Clustering. Cada uma destas técnicas e seu respectivo algoritmo é detalhada no trabalho de Jang et al. (1997).

Neste trabalho foi aplicada a técnica de "subtractive clustering" para o agrupamento das variáveis na criação dos sistemas híbridos neuro-fuzzy, que é obtida pelo comando *genfis2* do MATLAB. Essa função é aplicada sobre o conjunto de entradas e saídas, para determinação dos centros dos agrupamentos, assim gerando o número de regras e de funções de pertinência das entradas do sistema neuro-fuzzy.

Esta técnica é utilizada para geração do sistema de inferência (FIS) do modelo de sistema de adaptativo de inferência neuro-fuzzy (ANFIS), do tipo Sugeno, que é conhecido como modelo neuro-fuzzy do tipo 3.

Um dos inconvenientes do uso da técnica subtractive clustering é a necessidade da definição do raio de influência de cada *cluster*. O raio de influência é a distância do centro do cluster até a região limite do agrupamento. Neste trabalho, foi usado o método de tentativa e erro para se encontrar o melhor raio na geração dos sistemas híbridos *neuro-fuzzy*.

A aplicação da técnica permitiu de agrupamento dos dados reduziu o número de regras do sistema.

5.2 Rede Neural Artificial (RNA)

Uma RNA é um processador paralelamente distribuído constituído por unidades de processamento simples, nós ou neurônios, que têm a tendência natural de armazenar conhecimento experimental e torná-lo disponível para uso, Haykin (2000).

Redes neurais artificiais consistem de camadas de neurônios, onde cada neurônio é a unidade básica de processamento. A arquitetura da rede é estruturada de uma forma que os neurônios estão interconectados, conforme figura 9.




Figura 9: Arquitetura de uma Rede Neural. (1- Vetores de entrada do neurônio; 2- Pesos Sinápticos; 3 – Função de Ativação; e 4 – Saídas).

O algoritmo de treinamento define como será realizado o processo de aprendizagem da rede, ou seja, após um conjunto de padrões de entrada ser apresentado à rede, uma nova informação é obtida e modificações são realizadas nos parâmetros da rede, a fim de que o modelo represente o conhecimento sobre o conjunto de dados apresentado, de maneira que respostas adequadas sejam fornecidas pela rede para a solução do problema.

Uma das características importantes da rede neural é a robustez, ou seja, a rede é tolerante a falhas até um certo nível, entradas ou saídas não confiáveis. Devido ao seu aspecto paralelo, a rede neural executa várias operações idênticas e independentes simultaneamente, com rapidez e eficiência. O processo de aprendizagem é automático e os ajustes dos parâmetros da rede são realizados durante esse processo.

Outra característica importante é a capacidade da rede neural de generalizar, isto é, a partir do conhecimento já adquirido, a rede é capaz de responder a novas situações, nunca apresentadas a ela anteriormente. Por exemplo, um conjunto de padrões é dado como entrada, a rede é treinada, então um novo conjunto de padrões, distinto do anterior, é apresentado à rede neural que ainda é capaz de classificá-los.

A técnica de RNA tem sido bastante aplicada na construção de soft sensor, como nos trabalhos de Zanata (2007) e Jerbić (2007), já que elas se diferenciam das técnicas de inteligência artificial simbólica por não necessitarem de uma base de conhecimento na forma de regras. As redes neurais utilizam dados numéricos, podendo manipular informações incompletas e imperfeitas e, a partir delas, ser capaz de adquirir conhecimento no processo de aprendizagem.

5.3 Sistemas Fuzzy (Nebulosa)

Sistemas *fuzzy* são baseados na teoria da lógica *fuzzy* e dos conjuntos *fuzzy*, propostos por **Zadeh em 1965**. A lógica booleana define as variáveis como sendo verdadeiras ou falsas, 1 ou 0 respectivamente, enquanto na lógica *fuzzy*, as variáveis são mapeadas em graus de pertinência que variam de 0 a 1.

A lógica fuzzy foi inicialmente construída a partir dos conceitos já estabelecidos da lógica clássica. Operadores humanos foram definidos à semelhança dos tradicionalmente utilizados e outros foram introduzidos ao longo do tempo, muitas vezes por necessidades de caráter eminentemente prático.

Se um operador humano for capaz de articular sua estratégia de ação como um conjunto de regras da forma *Se... Então*, um algoritmo passível de ser implementado em computador pode ser construído.

O resultado é um sistema de inferência baseado em regras, no qual a Teoria de Conjuntos Fuzzy e Lógica Fuzzy fornecem o ferramental matemático para se lidar com as tais regras linguísticas.

Um conjunto fuzzy A em um universo X é definido por uma função de pertinência:

$$\mu_A(x): X \rightarrow [0,1] \quad (2)$$

O conjunto fuzzy é representado por um conjunto de pares ordenados:

$$A = \left\{ \frac{\mu_A(x)}{x} \right\} \quad x \in X \quad (3)$$

A função pertinência $\mu_A(x)$ indica o quanto x é compatível com o conjunto A . Um determinado elemento pode pertencer a mais de um conjunto fuzzy, com diferentes graus de pertinência.

A função pertinência do conjunto fuzzy define os graus de pertinência dos elementos, a figura 10 mostra as funções pertinências mais comuns.

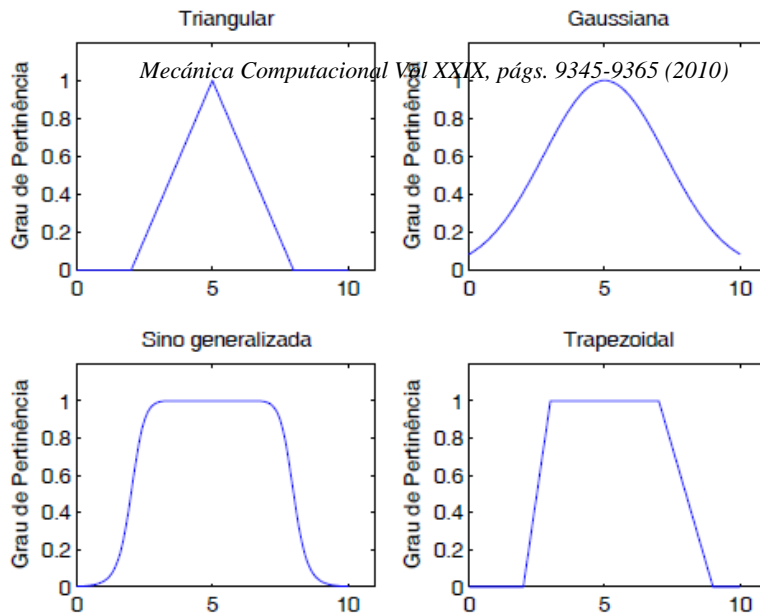


Figura 10: Funções pertinências mais comuns aplicadas nos conjunto fuzzy.

O conjunto suporte de um conjunto fuzzy A é o conjunto de elementos no universo X para os $\mu_A(x) > 0$. Um conjunto fuzzy cujo suporte é um único ponto x' com $\mu_A(x')$ é chamado de conjunto unitário fuzzy. Assim, um conjunto fuzzy também pode ser visto como o mapeamento do conjunto suporte no intervalo [0,1], o que implica em expressar o conjunto fuzzy por sua função de pertinência.

Os sistemas de inferência fuzzy (FIS) tem sido bastante aplicados na construção de soft sensor, como nos trabalhos de Arruda et al. (2007) e Takahashi(2006). A arquitetura de um sistema de inferência fuzzy é mostrada na figura 11.

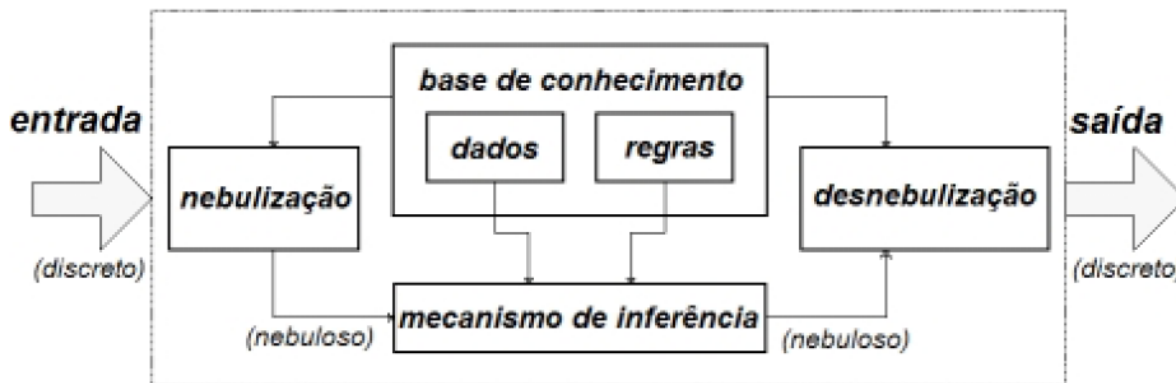


Figura 11: Sistema de Inferência Fuzzy (FIS). (Fonte: Takahashi H. J.(2006)).

5.4 Sistemas Híbridos Neuro-Fuzzy

A técnica híbrida neuro-fuzzy utiliza o sistema adaptativo rede neural, permitindo que este seja interpretado através de regras da lógica fuzzy.

Os modelos adaptativos são assim chamados por possuírem um algoritmo de aprendizado capaz de ajustar os seus parâmetros e/ou sua estrutura a partir dos dados da entrada real.

Entre os modelos adaptativos mais empregados na construção de um sensor destacam-se o criado de forma pioneira por Jang et al. (1997), o ANFIS (Sistema Adaptativo de Inferência Neuro Fuzzy). O modelo ANFIS pode ser construído carregando o comando *anfisedit* no Matlab.

A idéia básica de um sistema neurofuzzy é implementar um *Sistema de inferência Fuzzy*, numa arquitetura paralela distribuída de tal forma que os paradigmas de aprendizado comuns às *RNA's* possam ser aproveitadas nesta arquitetura híbrida.

A figura 12 mostra uma rede neuro-fuzzy, de modelo ANFIS, com três entradas (X_1, X_2, X_3) normalizadas, que são escalonadas dentro do intervalo de $[0,1]$, cujo

intervalo é dividido em níveis: e alto.

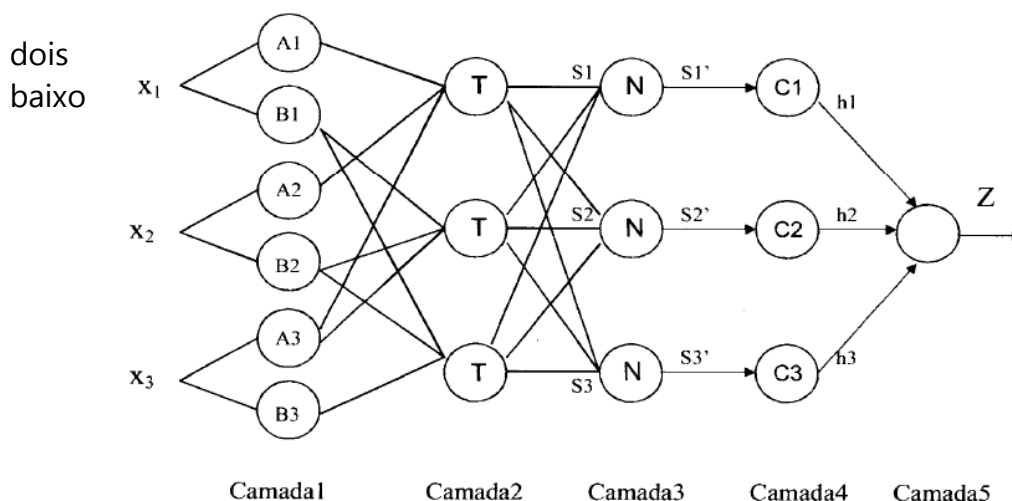


Figura 12: Arquitetura de um sistema Neuro-Fuzzy. (Fonte: TITO, E. A. H (2001))

Na figura acima a 1ª camada computa o grau de pertinência das entradas x_1, x_2 e x_3 , baseada nas funções de pertinência, A_i = alto e B_i = baixo, etapa conhecida como fuzzyficação; na 2ª camada cada nó corresponde a uma regra e calcula com que grau de pertinência o conseqüente da regra está sendo atendido (conhecida como disparo das regras); na 3ª camada é realizada uma normalização nos níveis de disparo das regras; a 4ª camada calcula as saídas dos neurônios obtidas pelo produto entre os níveis de disparo normalizados e valor do conseqüente da regra; a 5ª e última camada é conhecida como defuzzyficação, que calcula a saída do sistema.

Pagliosa (2007), define as vantagens de aplica um sistema neuro-fuzzy: as *RNA's* podem ser utilizadas para aprender as regras fuzzy; As regras fuzzy podem ser utilizadas para inicializar a estrutura de um *RNA* a fim de acelerar o treinamento e

melhorar a generalização; As RNA's podem ser usadas para refinar as regras fuzzy e funções de pertinência.

6 – VALIDAÇÃO DO MODELO

O sistema adaptativo de inferência neuro-fuzzy ANFIS foi utilizada na construção do sensor, pois a associação entre Rede neural e lógica fuzzy permite integrar as vantagens de cada abordagem e minimizar as deficiências de ambas.

Após o estudo de seleção de variáveis na seção 3 foram selecionadas 9 variáveis de entrada para o soft sensor. No entanto, para se obter um melhor desempenho da rede neuro-fuzzy, optou-se por utilizar uma regressão de um tempo de amostragem nas variáveis selecionadas, alterando o número de entradas de 9 variáveis para 18, sendo 9 variáveis instantâneas e 9 variáveis em um tempo de amostragem anterior. Conforme a figura 13.

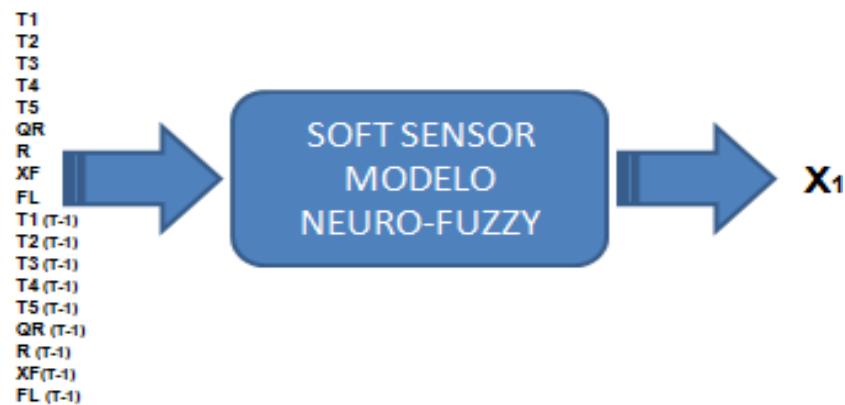



Figura 13 – Soft sensor para inferir a composição de metanol no topo da coluna (X_1).

Como discutido na seção 5 o número de entradas pode ser uma limitação no desempenho do sistema neuro-fuzzy. O aumento do número de entradas para 18, proporcionando também um aumento no conjunto de dados, não colocou em risco a viabilidade do soft sensor, uma vez que foi utilizada a técnica de agrupamento de dados "Clusterização".

No treinamento da rede neuro-fuzzy foram utilizados 440 pontos, estes foram divididos em dois grupos: treinamento "286" e validação "154". Logo, foi formado um sistema neuro-fuzzy com 18 entradas e uma saída, formando um conjunto de 42 regras fuzzy. A figura 14 mostra arquitetura da rede ANFIS.

Figura 14 – Arquitetura da Rede Neuro-Fuzzy.



Já o gráfico da Figura 15 mostra o resultado obtido no valor inferido da composição de topo feita pelo soft sensor, comparado com os valores desejados da composição.




Figura 15 – Comparação do valor estimado da composição feita pelo soft sensor.

Conforme o gráfico acima apresentado, o soft sensor apresentou bons resultados para estimar a composição de topo do processo de destilação binária.

O gráfico da Figura 16 apresenta o erro absoluto para cada ponto do soft sensor.




Figura 16 - Erro apresentado para os conjuntos dos dados.

O gráfico do erro mostra como a simulação do soft sensor se mostrou próxima da real, gerando um erro para todo o conjunto de dados na ordem de 10^{-3} .

7 CONCLUSÃO

Neste trabalho foi proposta uma estratégia de construção de um analisador virtual. Essa estratégia foi desenvolvida em cinco etapas. Na primeira etapa foi feita a aquisição de dados de um modelo dinâmico, de uma planta piloto. Na segunda etapa foram selecionadas as variáveis de entrada, com base em uma análise de sensibilidade. A terceira etapa consistiu em construir um modelo inferencial utilizando modelagem com a técnica neuro-fuzzy, que associa rede neural artificial e lógica fuzzy permitindo integrar as vantagens de cada abordagem e minimizar as deficiências de ambas. Para utilização da técnica neuro-fuzzy foi introduzida a quarta etapa do trabalho, onde foi possível diminuir o número de regras da lógica fuzzy para 42, permitindo o uso do conjunto de dados das 18 variáveis de entrada. A quinta e última etapa permitiu validar o modelo inferencial e comparar seus resultados com a composição real do topo da coluna de destilação.

O soft sensor construído mostrou bons resultados para inferenciar a composição de topo do processo. Assim, percebe-se a importância dessa ferramenta em

substituição às metodologias tradicionais de medição, possibilitando a medição dessa variável e de outras variáveis de interesse, em tempo real. Com isso, a aplicação do soft sensor torna-se viável diante das dificuldades operacionais a serem encontradas nos processos industriais.

Para trabalho futuros podem ser utilizadas outras técnicas para dimensionar o conjunto de dados das entradas, como por exemplo, a técnica de análise de componente principal dinâmica (DPCA), assim permita minimizar o erro de treinamento e validação da rede neuro-fuzzy.

8 REFERÊNCIAS

- Aguirre, L.A. *Introdução à identificação de sistemas: técnicas lineares e não-lineares aplicadas a sistemas reais*. Belo Horizonte: Editora UFMG, Cáp 4 e 11 da 2ª Ed. 2004.
- Arruda L. V. R. Flávio N.Jr.; Elaine Y. Nagai. *Um método neurofuzzy para construção de sensores virtuais*. Revista da Sociedade Brasileira de Redes Neurais (SBRN), Vol. 5, No.2, pp. 65-80, 2007.
- Conz V. *Desenvolvimentos de analisadores virtuais aplicados a colunas de destilação industriais*. Dissertação de mestrado. Universidade Federal do Rio Grande do Sul, UFRGS, Porto Alegre – RS, 2005.
- Cruz, J.C.G. *Identificação de Uma Torre de Retificação de Águas Ácidas Usando Redes Neurais Artificiais*, Dissertação de Mestrado do PPGEE, Universidade Federal de Minas Gerais, Belo Horizonte, Brasil, 1998.
- Diehl F.C.; Secchi, A.R.; Lusa, L.P.; Muniz, L.A.R.; Longhi, L.G.S. *Simulação operacional de uma torre de destilação atmosférica via Aspen Plus e avaliação de modelos de analisadores virtuais*. Sba Controle e Automação vol.20 n°3 Natal July/Sept, 2009.
- Facchin S.. *Técnicas de Análise Multivariável aplicadas ao Desenvolvimento de Analisadores Virtuais*. Dissertação de Mestrado. Universidade Federal do Rio Grande do Sul, UFRGS, Porto Alegre – RS, 2005.
- Fortuna,L.;Graziani,S.;Rizzo,A.;&Xibilia,M.G. *Softsensors for monitoring and control of industrial processes*. London, UK:Springer, 2007.
- Haykin, S.. *Redes Neurais: Princípios e Prática*. Cáp. 1 a 3, Bookman, 2001.
- JANG, R. J., SUN, C., E E., M. *Neuro-fuzzy and Soft Computing*. Prentice Hall, New Jersey, 1ª edição, 1997.
- Jerbić, I.; Bolf, N.; Pavelić, H.. *Development of Soft Sensors for Debutanizer Product Quality Estimation and Control*. Proceedings of European Congress of Chemical Engineering (ECCE-6), 2007.
- Kano,M.; Miyazaki,K.; Hasebe,S.; &Hashimoto,I. *Inferential control system of distillation compositions using dynamic partial least squares regression*. Journal ofProcessControl, 2000.
- Komulainen, T., Sourander, M., Jamsa-Jounela, S. L. *An online application of dynamics PLS to a dearomatization process*. Computers & Chemical Engineering, 28, 26611-2619, 2004.

- Lotufo F.A., Garcia C., *Sensores Virtuais Ou Soft Sensors: Uma Introdução*. DINCON, 2008.
- Mejdell, T., Skogestad, S. *Estimation of distillation compositions from multiple temperature measurements using partial-least-squares regression*. Industrial & Engineering Chemistry Research. (1991a).
- Mejdell, T., Skogestad, S. *Estimation of distillation compositions from multiple temperature measurements using partial-least-squares regression*. Industrial and Engineering Chemistry Research, 1991b)
- Pagliosa, A. L.; *Obtenção das Funções de Pertinência de um Sistema Neurofuzzy pelo Método de Kohonen*; Dissertação de Mestrado, Universidade do estado de Santa Catarina – UDESC, itajaí/sc, 2003.
- Secchi A. R., Cardozo N. S. M., Almeida N. E. Finkler T. F. *An Algorithm for Automatic Selection and Estimation of Model Parameters*. Proceedings of the International Symposium on Advanced Control of Chemical Processes vol. 2, p. 789-794. Gramado, Brasil, 2006.
- Sodré, C. H.; Wilson, A. J.; Jones, W. *The effect of large hold-up in a distillation column*. Proceeding of enpromer 2001. Santa fe : intec, 2001. V. 1. P. 349-354, 2001
- Takahashi J. H. *Predição de propriedades mecânicas de aços de alta resistência microligados utilizando técnicas de inteligência computacional*. Dissertação de Mestrado, Centro Universitário do Leste de Minas Gerais-UNILESTE, MG, 2006.
- Tito, E. A. H.; *Tópicos Avançados em Inteligência Artificial*, 2001; [http:// www.ele.puc-rio.br/labs/ica](http://www.ele.puc-rio.br/labs/ica).
- Zadeh, L.; *Fuzzy Sets*, Selected Papers by L. A. Zadeh, pág. 29 - 44.
- 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, vol. 15, pp. 39-52, 2005.
- Zanata, D. R. P. *Desenvolvimento de um Sensor Virtual empregando Redes Neurais para Medição da Composição em uma coluna de Destilação*. Dissertação de Mestrado, Universidade de São Paulo-USP, 2005.