

# Sistema Neuro-Nebuloso para Identificação de Processos de Incineração Multivariáveis Não-Lineares Discretos no Tempo

**Amílcar J. Pucciarelli, Felipe de M. Almeida & Gilmar Barreto**

Universidade Estadual de Campinas - UNICAMP,  
Faculdade de Engenharia Elétrica e de Computação - FEEC,  
Departamento de Máquinas, Componentes e Sistemas Inteligentes - DMCSI,  
Laboratório de Controle e Sistemas Inteligentes - LCSI,  
13083-852, Campinas, SP

E-mail: amilcar@dmcsi.fee.unicamp.br , felipe@dmcsi.fee.unicamp.br, gbarreto@dmcsi.fee.unicamp.br.

## 1. Resumo

*O controle de processos complexos não lineares com múltiplas entradas e múltiplas saídas é um problema importante e desafiador. Para desenvolver um controle que seja adaptativo e eficiente na manipulação das variáveis é necessário realizar a identificação do processo de forma a obter um modelo deste sistema. Sistemas neuro-nebulosos tem sido efetivamente usados para identificar sistemas dinâmicos não lineares, mas geralmente sistemas com única entrada e única saída são considerados. Processos de incineração de efluentes líquidos necessitam do desenvolvimento de controladores inteligentes em seu sistema de combustão e a identificação deste sistema complexo de incineração é a primeira etapa para o desenvolvimento do controlador. Este trabalho apresenta um modelo neuro-nebuloso que pode ser efetivamente usado para representar sistemas dinâmicos multivariáveis. Realizamos uma identificação do sistema de incineração de efluentes da empresa BASF, através da rede neuro-nebulosa ANFIS, onde utilizamos o algoritmo de agrupamento Gath-Geva modificado[1] para determinar a parte do antecedente do conjunto neuro-nebuloso.*

## 2. Introdução

Em problemas de controle adaptativo, o principal objetivo é desenvolver um controlador que possa se adequar às características da planta a ser controlada, com o objetivo de atender certas especificações de projeto pré-definidas [3]. Estes esforços iniciaram-se em 1960 e, em 1980 as pesquisas cresceram de maneira satisfatória em termos de duas grandes direções: controle auto-ajustável e controle baseado no modelo de referência. Este crescimento tem aberto as portas para uma larga faixa de aplicações. Porém, as pesquisas na área de algoritmos complexos de controle adaptativo ainda continuam, onde a utilização de estratégias computacionais voltadas ao comportamento inteligente, são largamente empregadas como ferramentas. Uma grande contribuição tem sido dada à

área de controle adaptativo inteligente com abordagens do tipo controle auto-ajustável considerando o impacto de redes neurais, algoritmos genéticos e sistemas nebulosos. A idéia principal deste trabalho partiu de uma necessidade industrial da empresa BASF, que possui um complexo incinerador de efluentes líquidos[4] onde os resíduos são incinerados por oxidação a alta temperatura. Este processo é controlado por um operador de sala de controle via sistema supervisório, onde as etapas de incineração são automáticas, mas o sistema digital de controle distribuído (SDCD)[7] não controla o processo de combustão. Devido a complexidade do sistema multivariável, que apresenta não linearidade em suas variáveis de entrada e saída, existe um operador por turno para executar tal função. Uma solução para este problema seria desenvolver um controlador inteligente para este processo de incineração.

Neste trabalho, realizaremos uma identificação do processo de incineração de efluentes da empresa BASF, através de uma rede neuro-nebulosa ANFIS. O algoritmo de agrupamento Gath-Geva modificado é utilizado para determinar os parâmetros nebulosos da rede.

A identificação de modelos neuro-nebulosos é uma efetiva ferramenta para a aproximação de sistemas dinâmicos não-lineares baseados em medida de dados[3]. Entre as diferentes técnicas de modelagem, o sistema de inferência neuro-nebuloso adaptativo (ANFIS) [8] tem nos chamado a atenção. Este modelo consiste de regras se-então com antecedentes nebulosos e funções matemáticas na parte do conseqüente onde são representados por uma estrutura de uma rede neural. A construção de um sistema de inferência é usualmente executada em dois passos. No 1º passo, os conjuntos nebulosos (funções de pertinência) das regras dos antecedentes são determinados. Isto pode ser executado manualmente, usando o conhecimento do processo, ou por algumas técnicas, dentro das quais, utilizamos agrupamentos nebulosos. No 2º passo os parâmetros das funções do conseqüente são estimados. Como estas funções tem variáveis livres de ruídos, o método padrão dos

mínimos quadrados pode ser aplicado. O problema em geral, é a identificação das funções de pertinência do antecedente, que é um problema de otimização não linear. O agrupamento nebuloso no espaço cartesiano das entradas e saídas é uma ferramenta que pode ser extensivamente usada para obter as funções de pertinência do antecedente. Características atrativas desta abordagem são as identificações simultâneas das funções de pertinência do antecedente junto com os modelos lineares locais do conseqüente. Neste trabalho, um processo de incineração multivariável é representado por um modelo neuro-nebuloso MIMO(Multiple Input Multiple Output), que consiste de um modelo MIMO linear ARX(Auto Regressive with exogenous inputs) com uma estrutura neuro-nebulosa. O algoritmo Gath-Geva modificado[1] é baseado na identificação da maximização da esperança (EM) de modelos que englobam um número de funções gaussianas. Este tipo de algoritmo de agrupamento pode ser facilmente usado para obter as funções de pertinência da primeira camada intermediária da rede neuro-nebulosa. Esta abordagem é estendida para processos MIMO e é aplicada para a identificação do processo de incineração de efluentes líquidos. Os resultados são comparados com os valores obtidos pela mesma estrutura neuro-nebulosa ANFIS, porém com a utilização do algoritmo de agrupamento Gustafson-Kessel (GK)[6], bem comum na literatura de identificação de sistemas não lineares.

### 3. Descrição do Processo de Incineração

De forma a realizar uma identificação mais precisa do sistema de incineração, é realizado um estudo das características do funcionamento do processo que segue abaixo[4].

#### 3.1 Processo de Incineração de Efluentes

O incinerador de efluentes líquidos, foi projetado para receber determinados resíduos de plantas industriais. Este incinerador é uma unidade projetada e fabricada pela T-Thermal, tipo Sub-X Down Fired, desenvolvido para incinerar resíduos líquidos por oxidação a alta temperatura, temos na figura (1), a representação desta unidade.

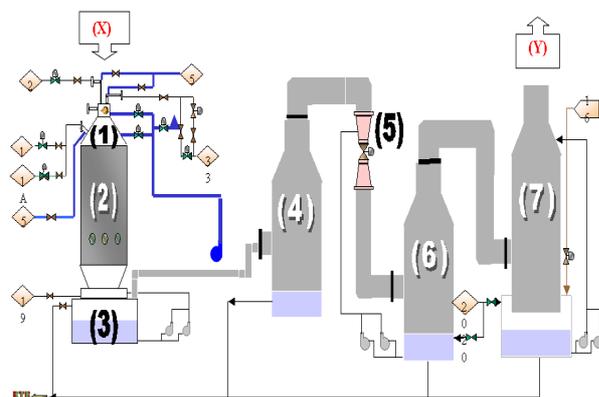


Figura 1 - Diagrama do Processo de Incineração

A unidade é basicamente composta de uma câmara de combustão (1), câmara de oxidação (2), tanque de resfriamento (3), torre de separação inicial (4), triturador de particulado (5), torre de separação final (6) e de um lavador de gases (7). Conforme discutido anteriormente na seção 2, a identificação do processo irá possibilitar desenvolver em propostas futuras, o controle da combustão da queima do efluente, através de um controlador inteligente, figura(2)

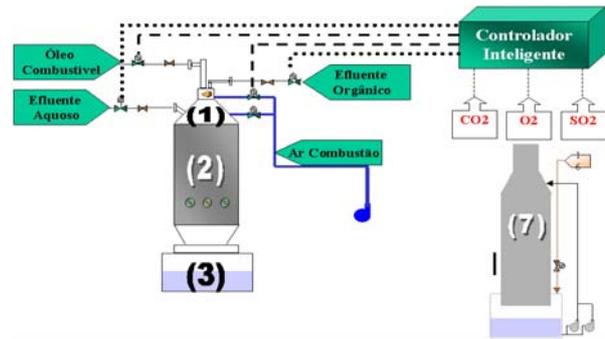


Figura 2 – Controlador adaptativo interagindo com as variáveis

## 4. Modelo Neuro-Nebuloso

Processos dinâmicos com múltiplas entradas e múltiplas saídas podem ser representadas pela função  $f$  não-linear dos vetores :

$$y(k+1)=f(y(k),..,y(k-n_a+1),u(k-n_d),..,u(k-n_b-n_d+1)) \quad (1)$$

onde  $y = [y_1, \dots, y_{n_y}]^T$  é um vetor de saída  $n_y$  dimensional,  $u = [u_1, \dots, u_{n_u}]^T$  é um vetor de entrada  $n_u$  dimensional,  $n_a$  e  $n_b$  são os atrasos máximos considerados para as saídas e entradas, respectivamente, e  $n_d$  é o tempo morto discreto.

Atualmente é muito difícil encontrar um modelo para descrever o sistema global  $f$  desconhecido, certamente vale a pena encontrar um modelo local linear para pontos de operação específica do processo. A modelagem é baseada na combinação de um número de modelos locais, onde cada modelo local tem uma região de operação predefinida no qual o modelo local é chamado de modelo baseado em regime de operação [2]. Este modelo é formulado como:

$$y(k+1) = \sum_{i=1}^c \lambda_i(\chi(k)) \left( \sum_{j=1}^{n_a} \alpha_j^i y(k-j+1) + \sum_{j=1}^{n_b} \beta_j^i u(k-j-n_d+1) + \gamma^i \right) \quad (2)$$

onde a função  $\lambda$ , descreve o regime de operação de  $i = 1, 2, \dots, c$ -th modelos ARX lineares locais, onde  $\chi = [\chi_1, \dots, \chi_n]^T$  é um vetor, no qual é usualmente um subconjunto do processo anterior de entrada e saída,  $\chi(k) = \{y_I(k), \dots, y_I(k-n_a+1), \dots, y_{n_y}(k-n_a+1), u_I(k-n_d), \dots, u_{n_u}(k-n_b-n_d+1)\}$  (3)

onde os modelos locais são definidos pelos parâmetros

$\Xi = \{\alpha_j^i, \beta_j^i, \gamma^i\}$  do conjunto neuro-nebuloso. O modelo completo, pode ser convenientemente representado por um sistema de inferência neuro-nebuloso adaptativo, que pode ser formulado por regras como:

$$R_i : \text{Se } \chi_l \text{ é } A_{i,l} \text{ e } \dots \text{ e } \chi_n \text{ é } A_{i,n} \text{ então } y^i(k+1) = \sum_{j=1}^{n_a} \alpha_j^i y(k-j+1) + \sum_{j=1}^{n_b} \beta_j^i u(k-j-n_d+1) + \gamma^i \quad (4)$$

onde  $A_{i,j}(\chi)$  é o  $i$ -th antecedente do conjunto para a entrada  $j$ -th e  $\zeta_i = [0,1]$  é o peso das regras. O valor de  $\zeta_i$  é baseado na intuição do especialista e na precisão de cada regra. A predição do 1º passo a frente

do modelo,  $y(k+1)$ , é deduzido pela ponderação dos pesos na saída de cada regra ,

$$y(k+1) = \sum_{i=1}^c \tilde{\lambda}_i(x(k)) y^i(k+1) \quad (5)$$

onde  $c$  é o número de regras e  $\tilde{\lambda}_i$  descreve a ponderação de  $i$ -th regra,

$$\tilde{\lambda}_i(x(k)) = \frac{\zeta_i \prod_{j=1}^n A_{j,i}(x_j)}{\sum_i \zeta_i \prod_{j=1}^n A_{j,i}(x_j)} \quad (6)$$

Para representar o conjunto neuro-nebuloso  $A_{j,i}(x_j)$ , a função de pertinência gaussiana é utilizada,

$$A_{j,i}(x_j) = \exp\left(-\frac{1}{2} \frac{(x_j - v_{i,j})^2}{\sigma_{i,j}^2}\right) \quad (7)$$

onde  $v_{i,j}$  representa o centro e  $\sigma_{i,j}^2$  a variância da função gaussiana.

## 5. Identificação dos Parâmetros do Consequente Neuro-Nebuloso

Os modelos locais podem ser interpretados como um comportamento dinâmico local do modelo neuro-nebuloso completo. A identificação dos parâmetros do consequente da regra, força o modelo linear ajustar o sistema separadamente e localmente, resultando nos consequentes das regras que são linearizações do sistema não linear [2]. O modelo pode ser interpretado com um sistema LPV (*Linear Parameter Varying*) descrito em (2), onde os parâmetros do consequente de cada regra são estimados, via mínimos quadrados ponderados.

Este modelo pode ser formulado de forma compacta :

$$y(k+1) = \sum_{i=1}^c \tilde{\lambda}_i(\chi(k)) [\mathcal{G}(k) I_{1 \times n_y}] \Xi_i^T + \xi(k) \quad (8)$$

onde  $\mathcal{G}(k)$  é o vetor regressor,

$$\mathcal{G}(k) = [y(k), \dots, y(k-n_a+1), u(k-n_d), \dots, u(k-n_u-n_d+1)]^T \quad (9)$$

$\Xi$  é o parâmetro da matriz de  $i$ -th modelos locais,

$\Xi_i = [\alpha_1^i, \dots, \alpha_{n_y}^i, \beta_1^i, \dots, \beta_{n_u}^i, \gamma^i]$  e  $\xi(k)$  é uma seqüência de ruído branco com média zero. A saída do modelo é linear nos elementos das matrizes  $\alpha_j^i, \beta_j^i$  e do vetor  $\gamma^i$ . Desta forma, estes parâmetros podem ser estimados através dos dados do processo de entrada-saída por técnicas de mínimos quadrados lineares. A identificação dos parâmetros do consequente para cada regra estão arranjadas da seguinte forma:

$$\mathcal{G} = [\mathcal{G}^T(1) | \mathcal{G}^T(2) | \dots | \mathcal{G}^T(N)]^T \quad (10)$$

$$Y = [y(2) | y(3) | \dots | y(N+1)]^T \quad (11)$$

$$\tilde{\lambda}_i = \begin{bmatrix} \tilde{\lambda}_i(1) & 0 & \dots & 0 \\ 0 & \tilde{\lambda}_i(2) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \tilde{\lambda}_i(N) \end{bmatrix} \quad (12)$$

Usando esta notação, a solução dos mínimos quadrados ponderados de  $\Xi_i$  é :

$$\Xi_i = [\mathcal{G}^T \tilde{\lambda}_i \mathcal{G}]^{-1} \mathcal{G}^T \tilde{\lambda}_i Y \quad (13)$$

## 6. Agrupamento para a Identificação do Antecedente

### 6.1 Formulação do Problema

O item anterior apresentou como a parte do consequente do modelo neuro-nebuloso pode ser identificado pelo método de mínimos quadrados ponderados para cada regra. O que torna mais difícil a identificação dos modelos neuro-nebulosos para processos não lineares é a identificação da direção dos dados da parte do antecedente destes modelos, que requerem otimização não linear. Para este propósito freqüentemente uma abordagem heurística com métodos de agrupamentos nebulosos são aplicados. O objetivo do agrupamento é particionar os dados identificados  $Z$  em  $c$  agrupamentos, onde a identificação dos dados é eficaz,  $Z = [\mathcal{G}, Y]$  é formado por uma matriz de regressão de dados  $\mathcal{G}$  e um vetor de saída  $Y$ , que podem ser agrupadas da seguinte forma  $Z_k = [\mathcal{G}(k), Y(k+1)]^T$ , onde o  $k$  subscrito denota as  $k$ th linhas da matriz  $Z$ . Os agrupamentos obtêm uma partição nebulosa dos dados  $Z$ . Esta partição é representada pela matriz  $U = [\mu_{i,k}]_{c \times n}$ , onde  $\mu_{i,k}$  é o elemento da matriz que representa o grau da pertinência nebulosa. A formas dos agrupamentos podem ser obtidas com diferentes tipos de algoritmos baseados em diferentes protótipos, variedades lineares ou pontos e com diferentes medidas de distância. Geralmente o algoritmo Gustafson-Kessel é aplicado para identificar modelos não lineares[6]. Uma desvantagem deste algoritmo é que somente os agrupamentos com igual volume podem ser encontrados e os grupos resultantes não podem ser

diretamente utilizados para formar as funções de pertinência. O algoritmo de Gath-Geva (GG) não sofre estes problemas. Gath e Geva interpretam os dados como variáveis aleatórias distribuídas normalmente e assumem uma distribuição gaussiana, com valores esperados  $v_i$  dos centros dos grupos e a matriz de covariância  $F_i$  é escolhida para gerar os dados com uma probabilidade  $p(n_i)$  à priori [5]. Em [1] mostra como o antecedente dos conjuntos nebulosos e os parâmetros do conseqüente correspondente dos modelos podem ser calculados. Para preservar o particionamento do espaço do antecedente, as transformações lineares nas variáveis de entrada podem ser utilizadas[5]. Este caminho, todavia, complica a interpretação das regras, onde a matriz de covariância pode obter elementos não nulos fora da diagonal principal[2]. Para formar um modelo facilmente interpretável que não utilize as transformações nas variáveis de entrada, o algoritmo de agrupamento GG é modificado, baseado na identificação da maximização da esperança (EM) de modelos que englobam um número de funções gaussianas. Neste trabalho, este algoritmo é estendido para a identificação de modelos neuro-nebulosos MIMO, que será aplicado no caso específico do incinerador, conforme discutido anteriormente, onde cada agrupamento contém uma distribuição de entrada, um modelo local e uma distribuição na saída.

$$p(\mathcal{G}, y) = \sum_{i=1}^c p(\mathcal{G}, y, n_i) \quad (14)$$

$$= p(y | \mathcal{G}, n_i) p(\mathcal{X} | n_i) p(n_i)$$

A distribuição na entrada é parametrizada como uma gaussiana incondicional [1] e define o domínio da influência de um agrupamento em um caminho similar para funções de pertinências multivariáveis (6).

$$p(\mathcal{X} | n_i) = \frac{\exp\left(-\frac{1}{2}(\mathcal{X} - v_i)^T (F_i^x)^{-1} (\mathcal{X} - v_i)\right)}{(2\pi)^{\frac{n}{2}} \sqrt{|F_i^x|}} \quad (15)$$

enquanto a distribuição de saída assume :

$$p(y | \mathcal{X}, n_i) = \frac{\exp\left(-\frac{1}{2}(y - \mathcal{G}^* \Xi_i^T)^T (F_i^y)^{-1} (y - \mathcal{G}^* \Xi_i^T)\right)}{(2\pi)^{\frac{no}{2}} \sqrt{|F_i^y|}} \quad (16)$$

onde as matrizes de covariância  $F^x$  e  $F^y$  são calculadas :

$$F_i^x = \frac{\sum_{k=1}^N (\mathcal{X}_k - v_i)(\mathcal{X}_k - v_i)^T p(n_i | \mathcal{G}_k)}{\sum_{k=1}^N p(n_i | \mathcal{G}_k)} \quad (17)$$

$$F_i^y = \frac{\sum_{k=1}^N (y_k - \mathcal{G}_k^* \Xi_i^T)(y_k - \mathcal{G}_k^* \Xi_i^T)^T p(n_i | z_k)}{\sum_{k=1}^N p(n_i | z_k)} \quad (18)$$

Quando a simplicidade e a interpretabilidade do modelo é importante, a matriz de covariância ponderada do agrupamento  $F^x$  é reduzida aos elementos da diagonal[1]. Assim a distribuição na entrada assume:

$$p(\mathcal{X} | n_i) = \prod_{j=1}^n \frac{1}{\sqrt{2\pi\sigma_{i,j}^2}} \exp\left(-\frac{1}{2} \frac{(\mathcal{X}_j - v_{i,j})^2}{\sigma_{i,j}^2}\right) \quad (19)$$

A identificação do modelo significa a determinação de parâmetros dos agrupamentos. Então, a identificação(EM) do modelo é reformulada para fornecer um algoritmo de fácil implementação, similar ao algoritmo GG, não utilizando transformações nas variáveis de entrada.

## 6.2 Algoritmo de Agrupamento GG Modificado Para a Identificação da Rede Neuro-Nebulosa

O agrupamento é baseado na minimização da soma das distâncias quadradas entre os pontos dos dados  $Z_k$  e o protótipo do próprio agrupamento  $n_i$ .

$$J(Z, U, n) = \sum_{i=1}^c \sum_{k=1}^N (\mu_{i,k}) D_{i,k}^2(z_k, n_i) \quad (20)$$

Para conseguir particionar um espaço nebuloso, os valores das pertinências têm que satisfazer as seguintes condições:

$$U \in \mathcal{R}^{c \times N} | \mu_{i,k} \in [0,1], \forall_{i,k}; \sum_{i=1}^c \mu_{i,k} = 1, \forall_k; 0 < \sum_{k=1}^N \mu_{i,k} < N, \forall_i \quad (21)$$

A minimização da função(20) representa um problema de otimização não linear que é sujeita as condições definidas em (21) e pode ser resolvida usando uma variedade de métodos, descrito a seguir como algoritmo GG modificado:

**Inicialização:** Dado um conjunto de dados  $Z$ , especificar o número de grupos, escolher um expoente ponderado(usualmente  $m=2$ )[2] e uma tolerância de término  $\epsilon > 0$ . Inicialize a matriz de partição (aleatoriamente)  $U = [\mu_{i,k}]_{c \times N}$ . Repita para  $(l) = 1, 2, \dots$

O peso  $\mu_{i,k} = p(n_i | \mathcal{G})$  denota a pertinência nebulosa .

**Passo 1 :** Calcule os parâmetros dos agrupamentos :

- Centro das funções de pertinência

$$v_i^{(l)} = \frac{\sum_{k=1}^N \mu_{i,k}^{(l-1)} \mathcal{X}_k}{\sum_{k=1}^N \mu_{i,k}^{(l-1)}}, \quad 1 \leq i \leq c \quad (22)$$

- Desvio padrão da função de pertinência Gaussiana

$$\sigma_{i,j}^{2(l)} = \frac{\sum_{k=1}^N \mu_{i,k}^{(l-1)} (x_{j,k} - v_{i,j})^2}{\sum_{k=1}^N \mu_{i,k}^{(l-1)}}, \quad 1 \leq i \leq c \quad (23)$$

- Parâmetros dos modelos locais em (13), onde os pesos da matriz  $\tilde{\lambda}_i$  são  $\tilde{\lambda}_i(k) = \mu_{i,k}^{(l-1)}$

- Covariância dos erros dos modelos locais em (17)

- Probabilidade a priori dos agrupamentos :

$$p(n_i) = \frac{1}{N} \sum_{k=1}^N \mu_{i,k} \quad (24)$$

- Peso (impacto) das regras :

$$\zeta_i = p(n_i) \prod_{j=1}^n \frac{1}{\sqrt{2\pi\sigma_{i,j}^2}} \quad (25)$$

**Passo 2 :** Calcule a medida da distância :

A medida da distância consiste em 2 termos , o 1º termo é baseado na distância geométrica entre o centro do agrupamento e o vetor  $\chi$ , enquanto o segundo é baseado nos modelos lineares locais :

$$\begin{aligned} \frac{1}{D_{i,k}^2(z_k, n_i)} &= p(y | \mathcal{G}, n_i) p(\chi | n_i) p(n_i) = \\ &= \zeta_i \prod_{j=1}^n \exp\left(-\frac{1}{2} \frac{(\chi_{j,k} - v_{i,j})^2}{\sigma_{i,j}^2}\right) * \\ &\exp\left(-\frac{(y - \mathcal{G}^* \Xi_i^T)^T (F_i^y)^{-1} (y - \mathcal{G}^* \Xi_i^T)}{(2\pi)^{\frac{m}{2}} \sqrt{|F_i^y|}}\right) \end{aligned} \quad (26)$$

**Passo 3 :** Atualize a matriz de partição :

$$\mu_{i,k}^{(l)} = \frac{1}{\sum_{j=1}^c (D_{i,k}(z_k, n_i) / D_{j,k}(z_k, n_i))^{2/(m-1)}}, \quad (27)$$

$$1 \leq i \leq c, 1 \leq k \leq N.$$

até  $\|U^{(l)} - U^{(l-1)}\| < \epsilon$

## 7. Identificação do Processo de Incineração Líquida

A identificação do processo de incineração de efluentes líquidos será realizada através de uma rede neuro-nebulosa ANFIS. Esta identificação obtém um modelo do processo após a sua etapa de estimação, sendo adequado sua implementação, por exemplo em um controlador adaptativo conforme citado na seção 2. Para obter uma melhor estrutura da rede, de forma aumentar a sua eficiência no processo de identificação, verificamos algumas características pertinentes ao sistema de incineração[4].

### 7.1 Estrutura da Rede Neuro-Nebulosa :

Devido as características abordadas podemos estruturar a rede de forma a realizar o desacoplamento dos dados de saída da estrutura do sistema MIMO em 3 sistemas MISO acoplados, onde verificamos a correlação entre os dados do sistema. Buscamos desta forma otimizar o processo de identificação da rede neuro-nebulosa, que segue descrito pela figura (3) :

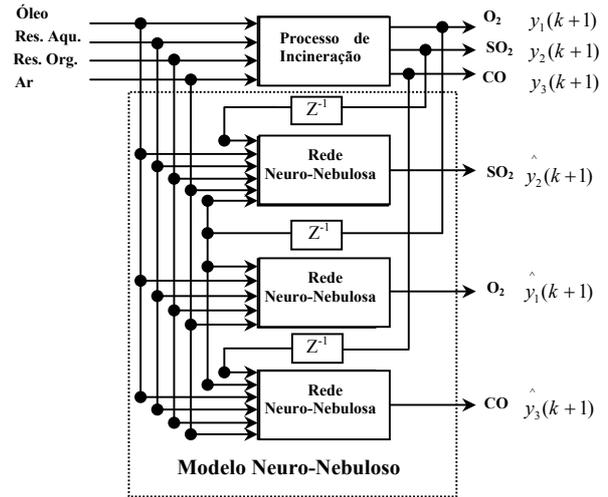


Figura 3 – Modelo Neuro-Nebuloso Multivariável

Conhecendo a estrutura do sistema onde teremos 3 redes neuro-nebulosas MISO (Multiple Input Simple Output), que acoplados geram um sistema MIMO. As regiões de operação do modelo local, são definidos no domínio das saídas do incinerador. Desta forma obtemos para cada sistema a seguinte configuração :

Para a Saída 1 (O<sub>2</sub>) :

$$\begin{aligned} R_i : \text{ Se } y_1(k) \text{ é } A_i \text{ então} \\ y_1^i(k+1) = \alpha_1^i y_1(k) + \beta_1^i u(k) + \gamma^i \end{aligned} \quad (28)$$

Para a Saída 2 (SO<sub>2</sub>) :

$$\begin{aligned} R_i : \text{ Se } y_2(k) \text{ é } A_i \text{ então} \\ y_2^i(k+1) = \alpha_2^i y_2(k) + \beta_2^i u(k) + \gamma^i \end{aligned} \quad (29)$$

Para a Saída 3 (CO) :

$$\begin{aligned} R_i : \text{ Se } y_3(k) \text{ é } A_i \text{ então} \\ y_3^i(k+1) = \alpha_3^i y_3(k) + \beta_3^i u(k) + \gamma^i \end{aligned} \quad (30)$$

A configuração da estrutura da rede neuro-nebulosa, é mostrada pela figura (4), onde o modelo neuro-nebuloso para a Saída 1 (O<sub>2</sub>) é apresentado. Para as outras saídas do processo, segue-se a mesma estrutura.

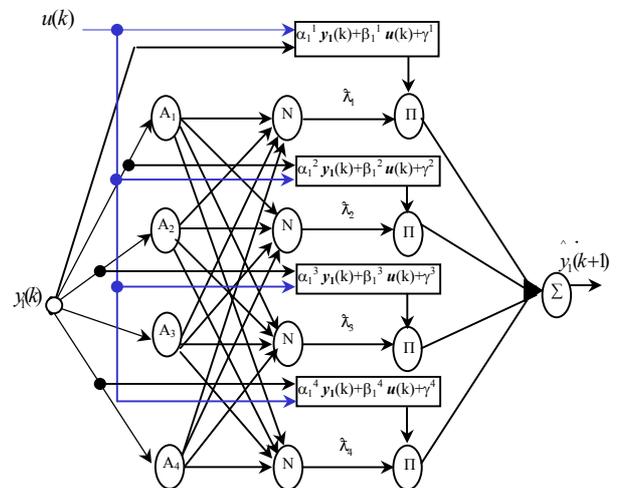


Figura 4 – Rede Neuro-Nebulosa ANFIS para a Saída (O<sub>2</sub>)

## 8. Resultados Computacionais

Realizamos a identificação do sistema utilizando o modelo neuro-nebuloso acoplado, com o algoritmo de agrupamento GG modificado. Realizamos 6000 observações (6000 minutos) para a etapa de treinamento e estimação da rede, obtendo o modelo do processo. Para a etapa de validação do modelo, outras 6000 observações foram realizadas. Dois critérios foram utilizados para a validação dos modelos:

-VAF : (*Variance Accounted For*)

$$\text{VAF} (\%) = 100 \times \left[ 1 - \frac{\text{var}(Y - \hat{Y})}{\text{var}(Y)} \right] \quad (33)$$

onde  $Y$  é a saída nominal do processo de incineração,  $\hat{Y}$  é a saída estimada pelo modelo e  $\text{var}$  é a variância do sinal. Quanto menor a diferença entre a saída real e a saída estimada, o valor de VAF se aproxima de 100%.

-MSE(*Mean Square Error*)

$$\text{MSE} = \frac{1}{N} \sum_{k=1}^N (Y_k - \hat{Y}_k)^2 \quad (34)$$

onde  $Y_k$  é a saída nominal do processo de incineração,  $\hat{Y}_k$  é a saída estimada do modelo e  $N$  é o número de pontos. Quanto menor a diferença entre a saída real e a saída estimada, o valor do MSE se aproxima de zero. Obtidos estes valores, uma análise comparativa é estabelecida entre o algoritmo Gath-Geva modificado (GG Mod.) e pelo algoritmo Gustafson-Kessel(GK). A tabela (1), apresenta a eficiência dos algoritmos de agrupamento nebulosos que foram utilizados no processo de identificação do sistema de incineração líquida para cada variável de saída :

Saída 1 (O <sub>2</sub> )	VAF (%)	MSE
GK	97,42	0,3
GG Modificado	98,53	0,24
Saída 2 (SO <sub>2</sub> )	VAF (%)	MSE
GK	96,58	0,42
GG Modificado	98,71	0,3
Saída 3 (CO)	VAF (%)	MSE
GK	96,14	0,52
GG Modificado	98,8	0,41

Tabela 1– Eficiência dos algoritmos de agrupamento nebulosos

Podemos observar que o melhor desempenho foi obtido pelo algoritmo de agrupamento nebuloso GG Modificado, onde aplicado em uma estrutura de uma rede neural, torna-se uma ferramenta poderosa para a identificação de sistemas multivariáveis não lineares. Um comparativo entre as saídas reais e estimadas pela rede ANFIS é apresentado pelas figuras 5, 6 e 7:

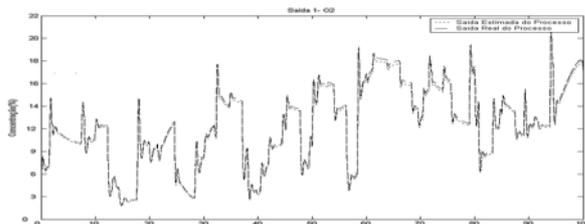


Figura 5– Comparação entre a saída de O<sub>2</sub> real x estimada

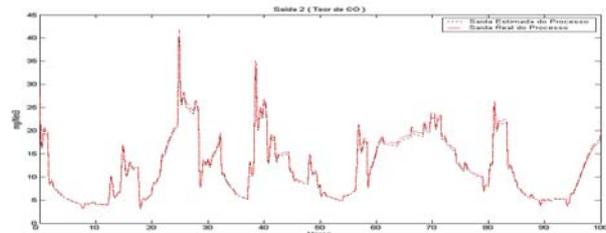


Figura 6– Comparação entre a saída de CO real x estimada

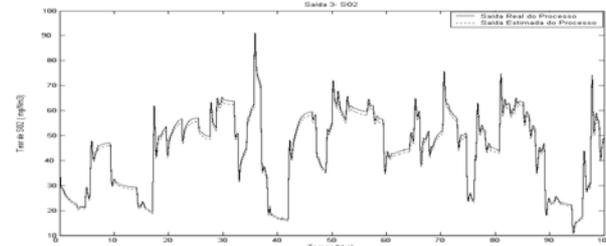


Figura 7– Comparação entre a saída de SO<sub>2</sub> real x estimada

## 9. Conclusões

Uma abordagem para a identificação de sistemas multivariáveis é discutida, onde o processo de incineração é representado por uma rede ANFIS multivariável. O antecedente da rede é identificado pelo algoritmo Gath-Geva modificado. Os resultados computacionais mostram o desempenho do modelo obtido pela estrutura abordada para a identificação do processo de incineração. Para trabalhos futuros, o desenvolvimento de um controlador para o sistema de combustão do processo utilizando o modelo obtido se faz necessário.

## 10. Referências

- [1] Abonyi, J. and Babuska, R.. *Modified Gath-Geva fuzzy clustering for identification of Takagi-Sugeno fuzzy models*. IEEE Transactions on Systems, Man and Cybernetics, Part B: 32:612-621, 2002.
- [2] Abonyi, J. and Szeifert, F.. *Identification of MIMO Process by Fuzzy Clustering*. IEEE International Conference on Intelligent Systems, Finland, 2001.
- [3] Babuska, R. and Verbruggen, H.. *Neuro-Fuzzy methods for nonlinear system identification*, Annual Reviews in Control, 21:73-85, 2003.
- [4] Cunha, J.R.. *Manual de Operações do Incinerador de Efluentes*. Rev.06, UTL-001, BASF, 2003.
- [5] Gath, G. and Geva, A.B.. *Unsupervised optimal fuzzy clustering*. IEEE Transactions on Pattern analysis and Machine Intelligence, 7:773-781, 1989.
- [6] Gustafson, D.E. and Kessel, W.C.. *Fuzzy clustering with fuzzy covariance matrix*. In Proceedings of the IEEE CDC, San Diego, pages: 761-766, 1979.
- [7] Honeywell. *Manual Técnico do Sistema Digital de Controle Distribuído*. MT-04, BASF, 1998.
- [8] Jang, J.S.R and Sun, C-T.. *Functional equivalence between radial basis function and fuzzy inference systems*. IEEE Transactions on Neural Networks, 4(1): 156-159, 1993.