

# **Modelagem Nebulosa com Otimização Genética de um Processo Não Linear: Um estudo de Caso**

**Anderson Eduardo Rodrigues Falci**

**Francisco José Gomes**

**Faculdade de Engenharia - UFJF  
Departamento de Engenharia Elétrica - Caixa Postal 422  
36001-970 - Juiz de Fora - MG  
Fone : ( 032) 229-3424  
chico@pet.ufjf.br**

## **Resumo**

O presente trabalho apresenta os resultados obtidos em uma modelagem nebulosa de um processo industrial não-linear, modelagem esta otimizada através de um algoritmo genético. Implementado heurísticamente, baseado em conhecimento de operadores, o modelo nebuloso não apresenta, inicialmente, resposta satisfatória. A introdução de um algoritmo genético, alterando as funções de pertinência dos sub-conjuntos nebulosos, conseguiu reduzir o erro do modelo garantindo sua eficácia. O algoritmo genético, embora necessite do ajuste de diversos parâmetros, revela-se de sintonia bem mais simples que as funções de pertinência, apesar de uma carga computacional considerável, dificultando aplicações em tempo real. A combinação destas duas técnicas se revelou um instrumento poderoso, robusto e de implementação simples para modelagem de processos.

**Palavras-Chave:** Modelagem de Processos, Sistemas Nebulosos, Algoritmo Genético.

## **Abstract**

This paper presents a fuzzy modeling of an industrial nonlinear process, optimized through a genetic algorithm. The initial implementation of the fuzzy model, heuristic based, was not very good. The genetic algorithm, changing the model membership functions, improved the modeling. The genetic algorithm, although requiring a high computational effort - that do not recommend its application for real time situation- and the tuning of several parameters, is easier to tune than the membership functions alone. The joint utilization of these two techniques has revealed itself a powerful, robust and simple approach for process modeling.

**Keywords:** Process Modeling, Fuzzy Systems, Genetic Algorithm.

**Tópico:** Conjuntos Nebulosos - Aplicações à Problemas de Engenharia



## 1. Introdução

A síntese de controladores, ou o estabelecimento de políticas ótimas ou sub-ótimas para processos e sistemas industriais passa invariavelmente pelo desenvolvimento de modelos adequados à estes propósitos. Em determinadas situações, quando os sistemas e processo envolvidos são não lineares, ou apresentam dinâmica não modeladas, ou complexidades similares, esta modelagem pode se revelar uma tarefa, por si só, mais trabalhosa que o desenvolvimento das políticas de controle e/ou otimização.

Como resposta a este tipo de questão novos procedimentos estão continuamente em desenvolvimento, culminando nas modernas técnicas de Inteligência Artificial e Sistemas Especialistas, onde merecem destaque a **Lógica Nebulosa** como ferramenta para modelagem e controle de processos e sistemas e os **Algoritmos Genéticos** como ferramenta de otimização (Kandel, 1994).

O presente trabalho apresenta o resultado de uma modelagem nebulosa de um processo industrial totalmente não linear (uma coluna de destilação de alta pureza utilizada na industria de semicondutores), com a otimização das funções de pertinência ocorrendo através da utilização de um Algoritmo Genético. A modelagem foi efetuada em duas malhas do processo ( topo e base da coluna), com dinâmicas e não-linearidades distintas, com procedimentos heurísticos, simulando a situação real dos processos industriais, onde os operadores são detentores de conhecimento, geralmente empírico, sem conhecimento analítico ou de técnicas de modelagem.

## 2. Sistemas Nebulosos e Genéticos: Implementação e Resultados

Um sistema lógico nebuloso geralmente é formado por quatro processos: “fuzzificação”, regras, inferência nebulosa e “defuzzificação”. O processo de “fuzzificar” uma variável de entrada significa calcular o grau de pertinência desta variável em um ou mais conjuntos nebulosos, enquanto uma regra nebulosa assume a forma

**if x is A then y is B**

onde **A** e **B** são variáveis linguísticas definidas por conjuntos nebulosos nos universos de variação **X** e **Y**, respectivamente. A inferência nebulosa, também definida como raciocínio



nebuloso, é um procedimento usado para tirar conclusões de um conjunto de regras nebulosas e uma ou mais condições e a “defuzzificação” produz uma saída com valor definido ( “crisp”) para o sistema lógico nebuloso a partir do conjunto nebuloso de saída do processo de inferência ( Yager, 1994).

Para o sistema em estudo, no topo da coluna, as variáveis de entrada e saída escolhidas foram, respectivamente, o refluxo e a composição do produto enquanto para a base as variáveis foram a energia entregue ao refeedor e a composição do produto na base da coluna.

Para o topo determinou-se o espectro de variação do refluxo de 9000 mol/h a 14000 mol/h, com a molaridade do produto variando de 0,900 a 1,00, sendo medidos 50 pontos neste intervalo. Para a base da coluna o espectro da variável energia foi estabelecido de 118 a 137 Mcal, com a variável molaridade variando de 0,00 a 0,77, sendo determinados também 50 pontos.

A função objetivo do sistema que avaliará a aptidão de cada cromossomo em relação aos outros é determinada por (Park, 1995):

$$J = 1/(1+e^2)$$

onde  $e^2$  é o erro médio quadrático definido como  $e^2 = \sum_{i=1}^{50} (Qbr_i - Qbm_i)^2 / \sum_{i=1}^{50} Qbr_i^2$

onde  $Qbr_i$  é o  $i$ ésimo valor de referência da molaridade produzido pelo  $i$ ésimo valor de entrada do processo e  $Qbm_i$  é o  $i$ ésimo valor da molaridade obtido pelo modelo nebuloso para a  $i$ ésima entrada.

A população inicial é formada por um cromossomo composto de valores de coeficientes de ajuste todos iguais a zero e outros 49 cromossomos formados por coeficientes com valores randômicos perfazendo o número total de 50 cromossomos da população, que se reproduzirão por 100 gerações. A presença do primeiro cromossomo com todos elementos iguais a zero visa garantir a possibilidade da atual configuração das funções de pertinência ser ótima.

As funções de pertinência utilizadas no modelo nebuloso são dadas por

$$f(x; \alpha_i, \beta_i, \gamma_i) = 0, \text{ se } x \leq \alpha_i$$

$$f(x; \alpha_i, \beta_i, \gamma_i) = (x - \alpha_i) / (\beta_i - \gamma_i) \text{ se } \alpha_i < x \leq \beta_i$$

$$f(x; \alpha_i, \beta_i, \gamma_i) = (x - \gamma_i) / (\beta_i - \gamma_i) \text{ se } \alpha_i < x \leq \gamma_i$$



$$f(x; \alpha_i, \beta_i, \gamma_i) = 0, \text{ se } x > \gamma_i$$

onde  $\alpha_i$ ,  $\beta_i$ ,  $\gamma_i$  são parâmetros de ajuste: a função de pertinência é triangular,  $\alpha_i$  é o limite à esquerda,  $\beta_i$  é o ponto correspondente ao vértice e  $\gamma_i$  é o limite à direita da função de pertinência. Para todo sub-conjunto nebuloso os parâmetros são alterados pelas seguintes equações:

$$\alpha_i = (\alpha_i + \delta_i) - \eta_i$$

$$\beta_i = (\beta_i + \delta_i)$$

$$\gamma_i = (\gamma_i + \delta_i) + \eta_i$$

onde  $\delta_i$  e  $\eta_i$  são os coeficientes de ajuste ( deslocamento horizontal da função sem alteração de forma e contração ou expansão da função, respectivamente, para o  $i$ -ésimo sub-conjunto nebuloso). Assim, o objetivo da aplicação do algoritmo genético no sistema é obter valores ótimos de  $\delta_i$  e  $\eta_i$  para se modificar as funções de pertinência relativas à variável de entrada ( refluxo e energia) e à variável de saída ( composição na base e topo da coluna ). Desta forma, um cromossomo correspondente a uma possível solução do problema ( funções de pertinência devidamente ajustadas) será formado por 12 alelos:

$$[\delta_1 \ \eta_1 \ \delta_2 \ \eta_2 \ \delta_3 \ \eta_3 \ \delta_1 \ \eta_1 \ \delta_2 \ \eta_2 \ \delta_3 \ \eta_3]$$

onde os três primeiros pares de coeficientes são relativos às funções de pertinência da variável de entrada e os três últimos relativos à variável de saída..

As figuras 1 e 2 mostram os resultados obtidos com a modelagem nebulosa, inicialmente sem a introdução do algoritmo genético e posteriormente com sua utilização, para o topo e base da coluna, respectivamente. A sintonia final do algoritmo genético, para os dois casos, foi a seguinte: 1) **Topo**: População : 50 cromossomos; Gerações : 100; Crossover: 100%; Mutação : 40%; 2) **Base**: População: 50 cromossomos; Gerações: 100; Crossover: 100%; Mutação: 30%.

### 3. Conclusão

Efetuiu-se uma modelagem nebulosa de um processo não-linear otimizado através de um algoritmo genético, que atuou sobre a forma das funções de pertinência do sistema.



Verificou-se que a utilização destas técnicas combinadas constitui uma ferramenta poderosa, simples e robusta para modelagem de processos, embora com um esforço computacional significativo. A sintonia do algoritmo genético não é trivial, embora se




Figura 1: Resultados obtidos para o processo e para o modelo nebuloso no topo da coluna: a) sem otimização b) otimizado. Tp indica o tempo computacional em minutos.




Figura 2: Resultados obtidos para o processo e para o modelo nebuloso na base da coluna: a) sem otimização b) otimizado. Tp indica o tempo computacional em minutos.

revele menos problemática que o ajuste isolado das funções de pertinência do modelo nebuloso. Os resultados obtidos encorajam estudos posteriores na utilização combinada destas técnicas, especialmente o desenvolvimento de adaptatividade de controladores nebulosos para tempo real.

#### 4. Bibliografia

- 1) Kandel, A. & G. Langholz, edit, **Fuzzy Control Systems**, CRC Press, Boca Raton, USA, 1994.
- 2) Yager, R.R. & D.P. Filev, **"Essentials of Fuzzy Modeling and Control"**, Wiley-Interscience, New York, 1994.



3) Park, D; A. Kandel and G. Langholz, " Genetic-Based New Fuzzy Reasoning Models with Application to Fuzzy Control, **IEEE Trans. Sys. Man and Cybernetics**, v. 24, n.1, 1995.

**Agradecimentos ao Programa PET/Capes, CNPq - Convênio 300961/89-8 e Fapemig - Convênio Tec 1527/93.**