

# MODELO NEUROBORROSO DE LA PRESIÓN DE LA CÁMARA DE MEZCLA EN UNA FUNDICIÓN DE COBRE

Juan Manuel Escaño

Centro Tecnológico Altair C/ El Barbero de Sevilla, 1 41006 Sevilla. jmesca@e-altair.org

Carlos Bordons

Dpto. Ingeniería de Sistemas y Automática, Escuela Técnica Superior de Ingenieros.

Camino de los Descubrimientos, s/n., 41092 Sevilla. bordons@esi.us.es

## Resumen

En este artículo se presenta un modelo neuroborroso de la presión de una cámara de mezclas de gases en una fundición de cobre, dentro del circuito de tratamiento de gases de la fábrica. Se ha usado el método de análisis de componentes principales para la reducción del espacio de variables de entrada y se ha obtenido además un modelo no recurrente, usándose para ello modelos neuroborrosos jerárquicos. El modelo se ha validado con datos experimentales obtenidos en una planta real.

**Palabras clave:** Modelos Neuroborrosos, Análisis de componentes principales, Modelado.

## 1 Introducción

El proceso de obtención del cobre tiene como subproducto una corriente de gases rica en azufre. Estos gases se pueden procesar para obtener ácido sulfúrico a partir de ellos. Tras la salida de los diferentes hornos donde se funde el mineral, los gases pasan por una cámara de mezcla antes de ser enviados a la fase de lavado previa a las plantas de obtención de ácido. En todo el circuito (y por tanto también en la cámara de mezcla) la presión de los gases debe ser negativa para impedir la emisión de los mismos al ambiente. Esta presión depende de diversas variables en la línea de producción y es bastante difícil de predecir, tanto obteniendo un modelo de primeros principios como por métodos de identificación. Es por tanto útil el empleo de métodos basados en las redes de neuronas artificiales o los sistemas neuroborrosos. Para realizar el modelo se tienen datos provenientes del sistema de control distribuido instalado en la planta referidos a 57 variables tomados cada 2 segundos. Para el modelo que se presenta aquí se trabajó con datos de tres días distintos, durante los que se realizaron además, pruebas en lazo abierto de diversas variables. En un primer estudio, se hicieron diversos experimentos para observar la correlación de las variables con la presión de la cámara de mezcla.

La organización del resto del artículo es la siguiente.




Figura 1: Mezcla de gases. Producción ácido sulfúrico

En la sección 2 se hace una breve introducción al modelado neuroborroso aplicado al sistema. En la sección 3 muestra la técnica de análisis de componentes principales, usada aquí para la reducción del espacio de variables. En las secciones 4 y 5 se muestran los resultados de los distintos modelos obtenidos. Finalmente, las conclusiones de este trabajo se resumen en la sección 6.

## 2 Modelado Neuroborroso

La meta del modelado borroso (Fuzzy modelling) es la obtención de un conjunto de reglas que describan la dinámica de la planta a través de unos datos experimentales. Los Sistemas de Inferencia Borrosos (FIS) son aproximadores funcionales genéricos, es decir, dado un cierto nivel de error, se puede encontrar un FIS que aproxime cualquier función con un error menor que el fijado. Para ello se pueden usar diversas técnicas, algunas provenientes del campo de las redes neuronales y otras de otros campos (estadística, algoritmos genéticos, etc). Muchos son los métodos que pueden encontrarse en la literatura para la identificación de un modelo borroso. Los métodos más comunes o conocidos son el *Fuzzy neuronal network* (FNN), el método de *Linguistic Equations* (LE) y los métodos de *Fuzzy clustering* (FC). El uso de Sistemas de Inferencia Borrosos (*Fuzzy Inference Systems*) para el modelado permite manejar bien

los procesos no lineales y dan un conocimiento del sistema que es imposible con el uso de redes neuronales. Los modelos basados en sistemas de inferencia neuroborrosos adaptativos (ANFIS) combinan la ventaja de las redes neuronales adaptativas (ANN), tales como la capacidad de aprendizaje y adaptación, y la *lógica borrosa*, es decir, el conocimiento basado en reglas y el manejo de incertidumbre y significancia del conocimiento. A diferencia de los sistemas basados en ANNs, los sistemas ANFIS pueden partir de una base de conocimiento previo, o bien, se puede añadir después la información que se desee para poder mejorar el modelo.

A la hora de establecer la estructura de un ANFIS, uno de los problemas es fijar las funciones de pertenencia. Un mayor número dará una mayor precisión en el conocimiento, pudiéndose provocar el manejo de numerosas reglas. Este problema de la explosión de reglas a mayor cantidad de términos lingüísticos, se puede subsanar con la aplicación de métodos de clustering que busquen la clasificación de datos en subconjuntos (*subset*). Además de la adecuada elección de reglas y funciones de pertenencia mediante una metodología, es importante la elección de las variables de entrada.

En un sistema simple, de pocas variables, es fácil la elección de las mismas observando la causalidad. Cuando el sistema está compuesto de muchas variables (como el caso que nos ocupa, en el que intervienen 57), acopladas entre ellas y difícilmente observable a simple vista, un método puede ser introducir el máximo número de variables en la entrada del FIS y dejar que un método de clustering decida los subconjuntos adecuados entre ellas junto con la entrada. Esto es algo, en ocasiones, poco práctico, perdiendo además una de las propiedades esenciales de los sistemas borrosos: el conocimiento del comportamiento del sistema.

En nuestro caso, queremos obtener un modelo de la variable PCM (presión de la cámara de mezcla). El camino inicial debería ser el estudio previo del sistema observando, mediante el análisis de correlaciones y los ensayos adecuados, las variables que afectan realmente a la PCM y después de ello, plantear un ANFIS con las variables mencionadas como entradas.

La metodología empleada en este trabajo es la siguiente: En primer lugar se han elegido suficientes datos para entrenar el sistema, en concreto se han usado 6000 datos de 57 variables. Se han elegido, además datos de otros días para poder validar el modelo y para evitar el sobreentrenamiento del sistema ANFIS [3]. Se han normalizado las variables, para evitar que la distinta

naturaleza y magnitud de las mismas, afecten al proceso de aprendizaje neuronal. Después se han probado algunas estructuras de sistemas ANFIS, eligiéndose las estudiadas en las secciones 4 y 5

Debido al acoplamiento dado entre las variables y la dificultad existente en la realización de pruebas experimentales, el estudio inicial no aporta la suficiente información para la implementación de un modelo adecuado. El uso del método PCA proporciona dos características: la obtención de nuevas variables incorreladas, la condensación de toda la información en un espacio mucho más reducido, proporcionando así una mayor simplificación del ANFIS. El inconveniente es la pérdida de simplicidad en el significado de las reglas del sistema borroso, pues las entradas requieren de interpretación.

### 3 Análisis PCA

En las situaciones donde hay un gran número de variables, es difícil obtener una visión general de las relaciones que puedan existir entre ellas. Uno de los métodos más importantes usados en el campo de la estadística multivariante es el Análisis de Componentes Principales (PCA), cuyo objetivo es reducir la dimensión del sistema, minimizando la pérdida de información.

Suponiendo  $p$  variables, la matriz de  $n$  datos es

$$X = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1p} \\ x_{21} & x_{22} & \dots & x_{2p} \\ \dots & \dots & \dots & \dots \\ x_{n1} & x_{n2} & \dots & x_{np} \end{pmatrix}$$

Cada fila  $i$  nos dará un dato en el tiempo  $t_i$  con  $p$  variables.

Las  $p$  variables son los vectores generadores del subespacio  $V$ . Lo que perseguimos es encontrar una nueva base de vectores ( $Y_1, Y_2, \dots, Y_k$ ) que definan un nuevo subespacio donde la información contenida sea la máxima. Esto es:

$$\begin{aligned} Y_1 &= w_{11}x_1 + w_{12}x_2 \dots + w_{1p}x_p \\ Y_2 &= w_{21}x_1 + w_{22}x_2 \dots + w_{2p}x_p \\ &\dots \dots \dots \\ Y_k &= w_{k1}x_1 + w_{k2}x_2 \dots + w_{kp}x_p \end{aligned}$$

Donde  $k < p$ .

Se demuestra que

$$\mu_Y = E(Y) = E(W^T X) = W^T E(X)$$

y que la matriz de covarianza de  $Y$  es igual a

$$\Sigma_Y = E\{(Y - \mu_Y)(Y - \mu_Y)^T\} = W^T \Sigma_X W$$

El objetivo es conseguir la máxima varianza de los datos en los ejes nuevos, es decir, la máxima  $\Sigma_Y$ , con la clara restricción de que sean ortonormales, esto es  $W^T W = I$ . En definitiva, se trata de maximizar

$$W^T \Sigma_X W - \lambda(W^T W - I)$$

derivando la expresión e igualando a cero, tenemos que

$$(\Sigma_X - \lambda I)W = 0$$

En definitiva, el problema se restringe a calcular los autovectores de  $\Sigma_X$

Las componentes  $W_j$  asociadas a los autovalores con más valor de  $\Sigma_X$ , son las significativas para representar los datos, denominándose éstas las Componentes Principales del sistema.




Figura 2: Componentes Principales

La primera componente es la correspondiente al mayor autovalor, la segunda al siguiente mayor, y así sucesivamente. Obteniéndose así un nuevo subespacio donde se encierra casi toda la información. A la hora de elegir las componentes principales, existen varios criterios. Uno de ellos es usar el número de autovectores  $l$  asociados a los autovectores que cumplan que

$$\frac{\sum_{i=1}^l \lambda_i}{\sum_{i=1}^n \lambda_i} \geq n$$

siendo  $n$  el porcentaje de información deseada.

Al aplicar el análisis de componentes principales al sistema en cuestión (con 57 variables), se obtuvieron 7 componentes principales que contienen el 95% de la información, reduciéndose considerablemente el espacio de las entradas al sistema

### 4 Modelo Dinámico

Un modelo borroso dinámico extiende el dominio de aplicación de las redes de neuronas bor-

rosas (FNN) a los problemas temporales (en el tiempo). Son llamados también Sistemas de neuronas borrosas recurrentes (RFNN). Son sistemas que poseen las mismas ventajas que las redes de neuronas recurrentes [5]. La recurrencia es debida a la realimentación de la salida para poder así captar la dinámica y el cambio. Estos sistemas presentan una dificultad: la propia estabilidad de los mismos una vez que están on-line. Los sistemas no dinámicos no tienen este problema, debido a la respuesta instantánea y la *unidireccionalidad* de la información.[6] [7]




Figura 3: Modelo neuroborroso dinámico

Debido a problemas encontrados en el entrenamiento, de la red dinámica clásica propuesta, en el caso que nos ocupa, se propuso un esquema distinto -también dinámico- pero incluyendo en el análisis PCA el valor anterior de la variable de salida, realimentando indirectamente la misma. Para el ajuste se usó la toolbox de MATLAB©de lógica borrosa [3]. La tabla 1 describe las características del sistema RFNN obtenido

Tabla 1: Características del Sistema Borroso

Tipo de sistema	T-Sugeno
Nº de nodos	294
Parámetros (lineales y no lineales)	128
Número de reglas	128
Tipo de salidas	Constantes
Funciones de pertenencia	gaussianas
Funciones de pertenencia por entrada	2

En la figura 3 puede verse un diagrama de la propuesta del sistema.

En la figura 4 se presenta la validación del modelo, siendo éste representado en línea azul.

El modelo así obtenido se ha validado para distintos días de funcionamiento, en los cuales las condiciones de operación cambian continuamente. La figura 5 muestra la predicción que ofrece el modelo en otra situación.




Figura 4: Resultados del modelo dinámico





Figura 5: Validación del modelo dinámico en otras condiciones de operación

## 5 Modelo No Recurrente

Para garantizar, en la práctica, la estabilidad del modelo en sí mismo, suele hacerse uso de modelos no dinámicos, o también llamados Feedforward. En nuestro caso, el resultado de proponer un sistema neuroborroso cuya salida sea la PCM y entradas las componentes principales resultantes del análisis sobre las 56 variables restantes después de un PCA, empeora los resultados, considerándolo inviable en la validación.

Un método alternativo aplicado en este trabajo es usar sistemas borrosos en serie. En la figura 6 se presenta un esquema del sistema propuesto. La idea propuesta consiste en encontrar otro sistema neuroborroso que tenga como entrada el resultado del PCA de las variables menos la PCM y como salidas los datos que se usaron para entrenar las entradas del sistema recurrente.

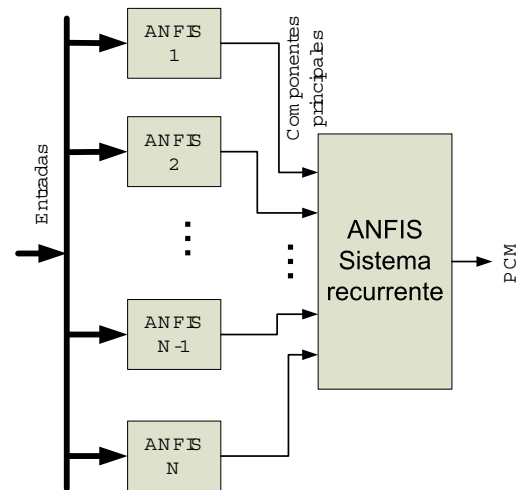


Figura 6: Modelo No-recurrente

Como se observa en la figura 6, en el sistema entran las variables distintas a la PCM y, después de un PCA, se obtienen las componentes principales que recogen el 95% de toda la información del sistema. La evaluación de los sistemas borrosos intermedios, dará como resultado cada una de las componentes principales propias del PCA usado para el modelo recurrente, obteniéndose con ellas, a través del sistema neuroborroso obtenido en la sección anterior, el valor de la PCM. Así pues, a partir de un modelo donde no se tiene en cuenta directamente los valores anteriores de la PCM, se obtiene primero, por estimación, las entradas del modelo recurrente.

La figura 7 describe con un poco más de detalle el esquema del modelo propuesto. Se observa la forma que tienen las distintas funciones de pertenencia de las siete entradas seleccionadas.




Figura 7: Esquema del modelo

En la figura 8 pueden observarse los resultados de este sistema (el modelo está representado en línea azul).




Figura 8: Resultados del modelo No-recurrente

## 6 Conclusiones

En este artículo se ha presentado modelos neuroborrosos de la presión de la cámara de mezcla de un proceso de producción de ácido sulfúrico, obteniéndose resultados aceptables para simulación y predicción. Se ha hecho uso del método PCA para la reducción del espacio de variables a la entrada. La técnica aquí presentada es un paso más para obtener una metodología adecuada para el modelado neuroborroso, siendo útil éste último al control basado en modelo. También se ha propuesto otro camino para la obtención de modelos no recurrentes basándose en el análisis de componentes principales y en el modelo dinámico obtenido.

Es de destacar que el modelo ha sido validado sobre una planta real, en la cual servirá de ayuda para el diseño y validación posterior de los controladores. La selección de las variables manipulables que tienen mayor influencia en la presión de la cámara de mezcla facilita la tarea de diseño de los controladores.

## Agradecimientos

Los autores desean agradecer la financiación de este trabajo al MEC (por su proyecto de investigación DPI2004-07444-C04-01)

## Referencias

- [1] A. Trabelsi, F. Lafont, M. Kamoun, G. Enea, "Identification of Nonlinear Multivariable Systems by Adaptative Fuzzy Takagi-Sugeno Model". *International Journal of Computational Cognition* (<http://www.YangSky.com/yangijcc.htm>). Volume 2. Number 3. Pages 137-153. 2004
- [2] Dallas E. Johnson. "Métodos Multivariados aplicados al análisis de datos". International Thomson Editores S.A. 2000
- [3] Mathworks Inc., "Fuzzy Logic Toolbox User's Guide". Version 2. 3rd printing. *The Mathworks Inc.* 1998
- [4] Jhy-Shyng, Jang, R. "Neuro-Fuzzy Modeling and Control". *Proceedings of the IEEE*, Vol 83, No. 3, March 1995
- [5] Lee, "Diagonal recurrent neural networks for dynamic systems control," *IEEE Trans. Neural Networks*, vol.6, pp. 144-156, Jan. 1995.
- [6] K. Kiriakidis, "Fuzzy Model-Based Control of Complex Plants". *IEEE TRANSACTIONS ON FUZZY SYSTEMS*, vol. 6, NO. 4, Nov.1998
- [7] Ching-Hung Lee, Ching-Cheng Teng, "Identification and Control of Dynamic Systems Using Recurrent Fuzzy Neural Networks", *IEEE TRANSACTIONS ON FUZZY SYSTEMS*, vol.8, no. 4, Aug. 2000