



Inteligencia Artificial. Revista Iberoamericana  
de Inteligencia Artificial

ISSN: 1137-3601

revista@aepia.org

Asociación Española para la Inteligencia  
Artificial  
España

Carbonell, P.; Díez, J.L.; Navarro, J.L.

Aplicaciones de técnicas de modelos locales en sistemas complejos

Inteligencia Artificial. Revista Iberoamericana de Inteligencia Artificial, vol. 4, núm. 10, verano, 2000,  
pp. 111-118

Asociación Española para la Inteligencia Artificial  
Valencia, España

Disponible en: <http://www.redalyc.org/articulo.oa?id=92541012>

- Cómo citar el artículo
- Número completo
- Más información del artículo
- Página de la revista en redalyc.org

redalyc.org

Sistema de Información Científica

Red de Revistas Científicas de América Latina, el Caribe, España y Portugal

Proyecto académico sin fines de lucro, desarrollado bajo la iniciativa de acceso abierto

# Aplicaciones de técnicas de modelos locales en sistemas complejos

P. Carbonell, J.L. Díez, J.L. Navarro

Departamento de Ingeniería de Sistemas y Automática. Universidad Politécnica de Valencia.  
pjcarbon@isa.upv.es, jldiez@isa.upv.es, joseluis@isa.upv.es

**Resumen.** Este artículo muestra cómo las técnicas basadas en modelos locales pueden ser empleadas con éxito para su aplicación al modelado y control de sistemas complejos. A partir de dichos modelos locales, y empleando técnicas de inferencia por base de reglas borrosas, se llega a modelos generalizados muy potentes que pueden ser utilizados para diseñar leyes de control estables. Se muestran dos aplicaciones de estas técnicas, para convertidores conmutados de potencia y el modelado de un proceso bioquímico llevado a cabo en un biorreactor.

**Palabras clave:** Modelado borroso, control borroso, sistemas complejos, modelos locales, clustering borroso.

## 1 Introducción

En el campo de la ingeniería de control, el modelado y la identificación son pasos previos imprescindibles en el diseño de sistemas de control, supervisión y detección de fallos. Sin embargo, existen muchos sistemas para los cuales no es posible aplicar las técnicas de modelado tradicionales debido a la falta de un conocimiento preciso y formal del sistema, a un comportamiento altamente no lineal de éste, al alto grado de incertidumbre en los datos, a características cambiantes, etc. A este tipo de sistemas los llamaremos *sistemas complejos*. Los sistemas flexibles de fabricación, la ingeniería aeroespacial, la ingeniería química y bioquímica, así como las ciencias ecológicas, sociales y financieras, son ejemplos de este tipo de sistemas.

Para tratar de modelar este tipo de sistemas se puede recurrir a su descomposición en un conjunto más o menos grande de submodelos que tienen un rango de validez limitado, que denominaremos modelos locales. El modelo global del sistema se obtendrá a través de la integración de los modelos locales utilizando una base de reglas borrosa que permite la selección de los modelos adecuados a la situación en que se encuentra el sistema [9]. Con este enfoque se dispone de una técnica simple e intuitiva para el modelado de procesos complejos, además de una herramienta muy útil para el diseño de sistemas de control.

Uno de los problemas que surgen a la hora de utilizar esta técnica es la selección del número de modelos locales que se deben emplear y la identificación de los distintos modelos locales utilizados. Una de las alternativas es la utilización de

---

<sup>1</sup> Este trabajo ha sido financiado por el proyecto GV97.TI-04-59 del programa de Proyectos de Investigación y Desarrollo Tecnológico de la Generalitat Valenciana

datos experimentales y extraer a partir de éstos la estructura del sistema de reglas borrosas (extracción de reglas) y los parámetros de los modelos locales (identificación paramétrica). Existen diversos métodos para resolver este problema basados en algoritmos genéticos, redes neuronales, plantillas o técnicas de agrupamiento (*clustering*) [1]. Estas últimas toman herramientas y algoritmos de los campos de reconocimiento de imágenes y de patrones.

Los algoritmos de agrupamiento borroso son los más adecuados para la identificación borrosa [13], [7], [1]. En función de la forma, densidad y tamaño de las *clases* (*clusters*), se debe utilizar una técnica diferente con una medida de distancia específica (similitud). Los algoritmos de agrupamiento más utilizados en este tipo de aplicaciones son el método de Fuzzy c-means (FCM) [3] y el método de Gustafson-Kessel (GK) [8].

El artículo se estructura en 5 apartados. En la sección 2 se presenta la metodología empleada en el modelado y control utilizando modelos locales, planteando la estructura del sistema propuesto, la formulación matemática utilizando modelos locales, la técnica de identificación borrosa utilizada y por último, se propone una técnica de control basada en el modelo desarrollado.

En el apartado 3 se muestra, como ejemplo de aplicación de esta propuesta, el modelado de un sistema bioquímico complejo. El sistema que se estudia no se puede modelar adecuadamente con las técnicas de caja blanca empleadas normalmente para estos procesos [2], por lo que nuevas propuestas son exploradas [15].

El apartado 4 describe el modelado y control de convertidores de potencia conmutados. Las propuestas iniciales de control de estos sistemas estaban basadas en la linealización en torno a un punto de trabajo [10]. Para esta solución, el sistema adolece de una fuerte dependencia con respecto al punto de trabajo nominal. Por otra parte, las propuestas previas de empleo de técnicas de control inteligente, principalmente basadas en la lógica borrosa [12], proponen la sustitución directa del regulador en el lazo por un controlador borroso. En este artículo se propone un nuevo enfoque, donde el comportamiento global del sistema se estimará por medio de una base de reglas borrosas a partir de un conjunto reducido de dichos modelos locales. Finalmente, en la sección 5 se presentan las conclusiones alcanzadas en el artículo, así como las posibles líneas de investigación futuras.

## 2 Modelado y control borroso basado en modelos locales

El enfoque tradicional del modelado se ha basado en una comprensión completa del sistema bajo estudio y de su comportamiento que, con un tratamiento matemático adecuado, da lugar a un modelo más o menos útil. Este enfoque es el llamado modelado de *caja blanca* (físico, mecánico o basado en principios fundamentales). Otro enfoque del modelado asume que el proceso en estudio puede ser aproximado por una estructura de *caja negra*, que no es más que un aproximador de funciones. En este caso, el problema del modelado se reduce a dar una estructura adecuada del aproximador que capture correctamente la dinámica y la no linealidad del sistema. También hay una serie de técnicas de modelado que intentan combinar las ventajas de los enfoques de caja blanca y caja negra, en las que las partes bien conocidas del sistema se modelan usando el conocimiento físico, y las partes con incertidumbre se modelan con técnicas de caja negra. Estos enfoques son los llamados híbridos, semimecánicos o de *caja gris*.

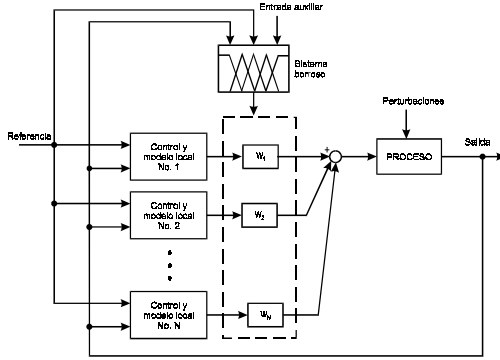
La estrategia que propone el modelado y control basados en modelos locales [9] consiste en dividir un sistema complejo en *subsistemas* más sencillos que puedan ser analizados de forma individual. La clave, por tanto, consiste en la elección de aquellos parámetros adecuados que permitan realizar dicha partición. Por otra parte, se hace necesario un elemento supervisor que sea de algún modo capaz de integrar de nuevo todos estos *subsistemas* en el sistema original.

Cuanto mayor sea el número de modelos locales elegidos, más sencillo será encontrar un controlador que funcione adecuadamente para cada uno de los regímenes. Sin embargo, esta propiedad se enfrenta a la denominada maldición de la dimensionalidad: una partición uniforme lleva a que el número de particiones crezca de forma exponencial con el número de variables.

Un control borroso directo realizado a partir de un conjunto de reglas heurísticas que describen dicha acción de control, puede ser interpretado como un modelo basado en modelos locales, ya que de algún modo cada regla corresponde a un estado o punto de trabajo del sistema.

Resulta, sin embargo, de mayor interés el enfoque del control indirecto basado en modelos locales. La estructura básica de este tipo de control, se muestra en la figura 1. El sistema borroso está formado por una base de reglas construidas a partir de la experiencia y del conocimiento a priori que se tiene

del comportamiento del sistema o bien usando datos experimentales. Este subsistema selecciona la combinación más adecuada de entre los distintos reguladores diseñados para varios puntos de trabajo. Se trata, por tanto de un sistema borroso de tipo Takagi-Sugeno, donde los consecuentes de las reglas son los distintos controladores diseñados para cada punto de trabajo. Los antecedentes, por su parte, son un conjunto de variables observadas que proporcionan la información necesaria para determinar de forma borrosa el régimen de trabajo del proceso.



**Figura 1.** Control borroso por modelos locales.

## 2.1 Modelos locales lineales

La dinámica de un sistema puede ser descrita según la ecuación de estado:

$$\dot{\mathbf{x}} = f(\mathbf{x}, \mathbf{u}, \mathbf{p}) \quad (1)$$


donde  $\mathbf{x}$  es el vector de estado,  $\mathbf{u}$  es el vector de entradas de control y  $\mathbf{p}$  es el vector de parámetros que determinan el régimen de funcionamiento.

Para este sistema, el estado de equilibrio correspondiente a un punto de funcionamiento viene dado por

$$0 = f(\mathbf{x}_{0i}, \mathbf{u}_i, \mathbf{p}_i) \quad (2)$$

En torno a este punto es posible determinar un modelo lineal de validez local, como el mostrado en la figura 2, por linealización entrada/salida de la ecuación de estado:

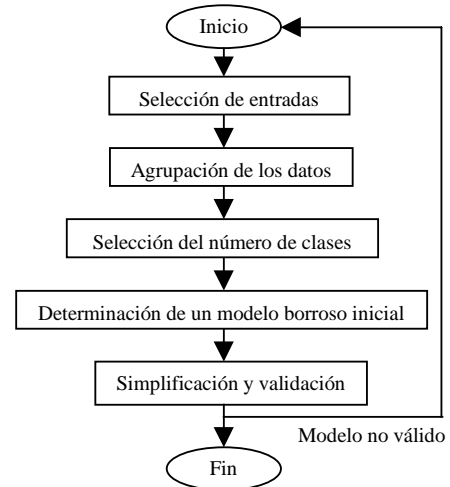
$$\begin{aligned} \dot{\mathbf{x}} &= \mathbf{x}_{0i} + \left. \frac{\partial f}{\partial \mathbf{x}} \right|_{\mathbf{x}_{0i}, \mathbf{u}_i, \mathbf{p}_i} (\mathbf{x} - \mathbf{x}_{0i}) + \left. \frac{\partial f}{\partial \mathbf{u}} \right|_{\mathbf{x}_{0i}, \mathbf{u}_i, \mathbf{p}_i} (\mathbf{u} - \mathbf{u}_{0i}) = \\ &= \mathbf{A}_i (\mathbf{x} - \mathbf{x}_{0i}) + \mathbf{B}_i (\mathbf{u} - \mathbf{u}_{0i}) \end{aligned} \quad (3)$$



**Figura 2.** Modelo local en torno a su punto de equilibrio.

Si ahora se selecciona un conjunto finito de regímenes de trabajo  $\{\mathbf{u}_i, \mathbf{x}_i, \mathbf{p}_i; i = 1 \dots N\}$ , y se define para cada una de las variables un conjunto borroso  $\{\mathbf{u}^{(i)}, \mathbf{x}^{(i)}, \mathbf{p}^{(i)}\}$  con función de pertenencia centrada en dicho punto de trabajo, es posible establecer un modelo general borroso basado en los modelos locales correspondientes a estos puntos, según la base de reglas borrosas de Takagi-Sugeno:

$$\begin{aligned} R^{(i)} : & \text{IF } \mathbf{u}(k) \text{ is } \mathbf{U}^{(i)} \text{ AND } \mathbf{x}(k) \text{ is } \mathbf{X}^{(i)} \text{ AND } \mathbf{p}(k) \text{ is } \mathbf{P}^{(i)} \text{ THEN} \\ & \mathbf{x}(k+1) = \mathbf{x}_{0i} + \mathbf{A}_i (\mathbf{x}(k) - \mathbf{x}_{0i}) + \mathbf{B}_i (\mathbf{u}(k) - \mathbf{u}_{0i}) \end{aligned} \quad (4)$$



**Figura 3.** Esquema sistematizado de identificación de modelos borrosos mediante técnicas clustering.

## 2.2 Identificación estructural y paramétrica

Disponer de un modelo analítico, como el que se presenta en (1), del sistema que se pretende controlar no siempre es posible. Sin embargo, si los estados del sistema en estudio son medibles, existe la posibilidad de realizar una serie de ensayos sobre el sistema y aplicar a los datos obtenidos algún proceso de identificación del que se obtengan bases de reglas borrosas como las descritas en (4). El proceso de identificación de modelos borrosos es iterativo por naturaleza. Los métodos sistematizados de identificación borrosa mediante técnicas de clustering ([13], [7], [1]) siguen una estructura similar, consistiendo en la repetición, para diferentes

elecciones de diversos parámetros, de los pasos que aparecen en la figura 3.

El algoritmo de identificación aplicable en estas condiciones (estados medibles y series de datos empíricos) sigue el de la figura 3, y ha sido definido en [5].

Para la selección de entradas se propone emplear el método heurístico propuesto por Sugeno [13]. Para la selección de las entradas entre un conjunto de variables candidatas, el método se basa en ir incrementado el número de entradas una a una y evaluando el criterio de regularidad (5), hasta alcanzar un mínimo local. Para ello se divide el conjunto de datos disponibles en dos grupos, A y B, y se evalúa la función:

$$RC = \frac{\sum_{i=1}^{k_A} (y_i^A - y_i^{AB})^2 / k_A + \sum_{i=1}^{k_B} (y_i^B - y_i^{BA})^2 / k_B}{2} \quad (5)$$


donde:  $k_A$  y  $k_B$  son el número de datos de los grupos A y B,  $y_i^A$  e  $y_i^B$  son las salidas correspondientes a los datos de A y de B,  $y^{AB}$  es la salida estimada para la salida de los datos de B por el modelo identificado con los datos de A, e  $y^{BA}$  es la salida estimada para la salida de los datos de A por el modelo identificado con los datos de B.

Para determinar el número óptimo de clusters se aplica de forma iterativa el índice de varianza de Sugeno [13] y el de dispersión de Emami [7] para cada número de clusters a estudiar. El valor que determine la convergencia de ambos índices se tomará como válido.

Cuando sea necesario aplicar el algoritmos de clustering (agrupación de datos y determinación de un modelo borroso inicial), se empleará el algoritmo GK [8], dadas sus adecuadas propiedades de detección de clusters lineales [1].

Para la determinación de un modelo borroso inicial de Takagi-Sugeno, los clusters determinados en el proceso de agrupación de los datos permiten definir funciones de pertenencia borrosas en el espacio n-dimensional de las entradas para los antecedentes de las reglas. Los parámetros de las funciones lineales de los consecuentes serán ajustados por mínimos cuadrados.

Los pasos de simplificación y validación las realizará un experto, dado que no existen referencias teóricas al respecto.



**Figura 4.** Modelos borrosos de caja negra.

Con el algoritmo propuesto se pueden determinar, de forma automática modelos de caja negra como el de la figura 4 con estructuras del tipo de las formuladas en (4).

### 2.3 Control borroso basado en modelos locales

El control de un sistema modelado según (4) puede ser ejercido empleando de nuevo la base de reglas borrosa, que ahora actúa como elemento supervisor de ajuste de la ganancia de control por estimación del punto de trabajo a partir de leyes de control local:

$$R^U : \text{IF } \mathbf{u}(k-1) \text{ is } \mathbf{U}^U \text{ AND } \mathbf{x}(k) \text{ is } \mathbf{X}^U \text{ AND } \mathbf{p}(k) \text{ is } \mathbf{P}^U \text{ THEN} \quad (6)$$

$$\mathbf{u}(k) = \mathbf{u}_{0j} + \mathbf{K}_j(\mathbf{x}(k) - \mathbf{x}_{0j})$$

Aquí es donde puede verse la utilidad del empleo de modelos locales lineales, ya que esto permite el planteamiento a su vez de leyes de control local lineales estables, según un diseño adecuado de la realimentación del estado mostrada en (6).

Finalmente, se obtiene una expresión para el lazo cerrado dada por

$$\mathbf{x}(k+1) = \sum_{i=1}^N \sum_{j=1}^N \mathbf{x}_{0i} + \omega_i(k) \omega_j(k) [\mathbf{A}_i + \mathbf{B}_i \mathbf{K}_j] \mathbf{x}(k) - \mathbf{x}_{0i} \quad (7)$$

siendo  $\omega_i(k)$  la función base borrosa [16] correspondiente a la regla  $i$  en el instante  $k$ .

El hecho de que cada modelo local sea estable en lazo cerrado, no asegura la estabilidad global para cualquier régimen de trabajo, tal y como muestra Tanaka en [12] con un contraejemplo.

Una condición suficiente de estabilidad del sistema en lazo cerrado expresado en (7) es la existencia de una matriz común definida positiva  $\mathbf{P}$  tal que verifique para todos los modelos locales la desigualdad matricial lineal

$$(\mathbf{A}_i + \mathbf{B}_i \mathbf{K}_i)^T \mathbf{P} (\mathbf{A}_i + \mathbf{B}_i \mathbf{K}_i) - \mathbf{P} < 0 \quad (8)$$

verificando al mismo tiempo para todos los pares de modelos locales la desigualdad matricial lineal

$$\left( \frac{\mathbf{A}_i + \mathbf{B}_i \mathbf{K}_j + \mathbf{A}_j + \mathbf{B}_j \mathbf{K}_i}{2} \right)^T \mathbf{P} \left( \frac{\mathbf{A}_i + \mathbf{B}_i \mathbf{K}_j + \mathbf{A}_j + \mathbf{B}_j \mathbf{K}_i}{2} \right) - \mathbf{P} < 0 \quad (9)$$

tal y como se muestra en [4].

### 3 Aplicación al modelado de biorreactores

El proceso de producción de  $\beta$ -glucosidasa por fermentación aeróbica en un biorreactor [11] viene descrito por:

$$\begin{aligned} \dot{x} &= \mu(x, e, s, t) \cdot x \\ \dot{e} &= \pi(x, e, s, t) \cdot x \\ \dot{s} &= \alpha(x, e, s, t) \cdot x \\ \dot{p} &= \beta(x, e, s, t) \cdot x \end{aligned} \quad (10)$$

En estas ecuaciones se describe la evolución dinámica de las variables medibles, de las que se pretende obtener un modelo, y que son la concentración de biomasa  $x(t)$ , la concentración de etanol  $e(t)$ , la concentración de glucosa  $s(t)$  y la concentración de producto  $p(t)$ . Dicha evolución viene definida por unas funciones  $\mu$ ,  $\pi$ ,  $\alpha$ ,  $\beta$  con dependencia de todas las variables del proceso.

Se dispone de un conjunto de datos experimentales, correspondientes a cuatro ensayos en las mismas condiciones de la producción de  $\beta$ -glucosidasa, con la particularidad de ruido en los datos. Adicionalmente, se adquiere una serie de datos en otras condiciones que se empleará para validación. Además, se dispone de un modelo del sistema asumiendo una ley de crecimiento de Haldane [2] cuyos parámetros han sido ajustados por algoritmos genéticos [11], que responde perfectamente al comportamiento del sistema en las condiciones de los cuatro ensayos. Sin embargo, dada la gran complejidad del sistema en estudio y el desconocimiento físico de algunos de los mecanismos de su evolución, el modelo descrito no se comporta bien con los datos de validación. A pesar de esto, el modelo se empleará para obtener series de datos sin ruido con los que realizar la identificación del sistema complejo.

Como primera idea de modelado se propone emplear el algoritmo dado por la figura 3 para obtener cuatro modelos borrosos MISO (uno por variable a modelar:  $x$ ,  $e$ ,  $s$  y  $t$ ) de caja negra como el de la figura 4. Sucesivas ejecuciones del algoritmo, para diferentes datos de entrenamiento en las mismas condiciones, llevan a otros tantos modelos:

- $\text{Bio}_{\text{SR}}$ : modelo de caja negra obtenido desde datos sin ruido (salidas modelo caja blanca)
- $\text{Bio}_{\text{CR}}$ : modelo de caja negra obtenido desde datos reales (media de los datos reales de los cuatro ensayos disponibles)

La validación de cada uno de los modelos obtenidos se ha realizado con los siguientes grupos de datos:

- 1: Datos sin ruido
- 2: Datos reales
- 3: Datos de validación (datos de un ensayo real con otras condiciones iniciales)
- BA: Simulación del sistema en bucle abierto


Los resultados de dicha validación han sido resumidos en la tabla 1, atendiendo a valores cuantificables de un índice de funcionamiento (IF) definido como error cuadrático medio entre la estimación y la salida esperada. Para hacer más comprensibles los resultados, se han definido etiquetas de la forma MB ( $\text{IF} < 10^{-3}$ ), B ( $\text{IF} < 10^{-2}$ ), R ( $\text{IF} < 10^{-1}$ ) y M ( $\text{IF} < 1$ ).

Modelo	Ensayo			
	1	2	3	BA
$\text{Bio}_{\text{SR}}$	MB	R	M	R
$\text{Bio}_{\text{CR}}$	B	B	M	M

**Tabla 1.** Validación modelos de caja negra.

Dada la gran complejidad del sistema en estudio los resultados de estos modelos no son demasiado buenos. Esto es debido, principalmente, a que el sistema tiene dos modos de funcionamiento bien diferenciados dependiendo de un valor crítico de concentración de glucosa ( $s=0.1$  mg/l), como se dedujo heurísticamente de la observación de los datos experimentales disponibles.

Se propone un cambio de estrategia y emplear el conocimiento heurístico y físico que se dispone del sistema para llegar a obtener modelos de caja gris del estilo de la figura 5.



**Figura 5.** Modelos borrosos de caja gris.


Tomando las ecuaciones (10) se pretende obtener un modelo borroso de caja negra de cada uno de los parámetros ( $\alpha$ ,  $\beta$ ,  $\mu$  y  $\pi$ ) en cada modo de funcionamiento ( $s \leq 0.1$  y  $s > 0.1$ ). Los resultados de la

validación para los modelos se resumen en la tabla 2, empleando los mismos criterios descritos para la tabla 1.

Modelo	Ensayo			
	1	2	3	BA
GRIS <sub>SR</sub>	MB	MB	MB	B
GRIS <sub>CR</sub>	R	R	MB	M

**Tabla 2.** Validación modelos de caja negra.

El modelo GRIS<sub>SR</sub> obtenido de esta forma se ajusta muy bien a los datos experimentales obtenidos para todas las variables, incluso para los datos del ensayo en condiciones iniciales diferentes a las del entrenamiento, para los cuales no era capaz de responder correctamente el modelo de caja blanca. En la figura 6 se pueden observar los resultados para cada una de las variables modeladas, siendo la línea continua la salida del modelo y quedando marcados con aspas los valores experimentales.



**Figura 6.** Comportamiento del modelo GRIS<sub>SR</sub>.

El sistema no ha sido controlado, pero tras el proceso de modelado propuesto se llega de forma automática a la obtención de un modelo borroso de Takagi-Sugeno como el de (4), por lo que podrían aplicarse la técnicas de control descritas en 2.3.

#### 4 Aplicación al modelado y control de convertidores de potencia

Como ejemplo de aplicación de técnicas de control basadas en modelos locales, se presenta en este apartado su empleo en convertidores dc/dc conmutados de potencia. Se trata de sistemas de gran complejidad en su dinámica, ya que la presencia de conmutadores hace que dicho sistema evolucione entre varias topologías dentro de su ciclo de conmutación. El control se ejerce por medio de la selección de la secuencia de conmutaciones, siendo su objetivo el mantenimiento de una de sus variables

de estado, la correspondiente a la tensión de salida  $v_o$ , en un valor de referencia estático.

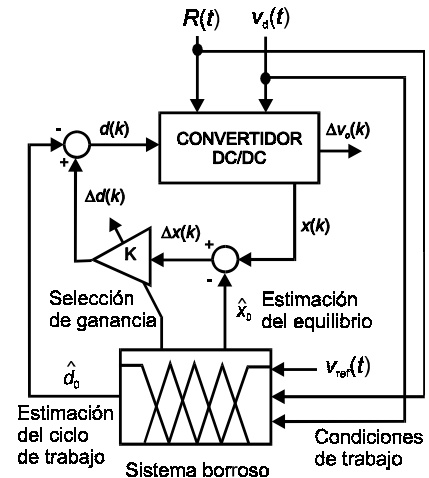
Por lo tanto, el sistema va a trabajar generalmente en torno a un estado de equilibrio, de manera que su comportamiento puede analizarse desde el punto de vista de un modelo lineal con perturbaciones. Esto permite realizar una reducción del número de reglas necesarias para su modelado según la estructura propuesta en (4), ya que el espacio de regímenes de funcionamiento  $P(v_o, R, v_d)$  viene determinado por un número reducido de parámetros:

- $v_o$  : tensión de referencia de salida,
- $R$  : resistencia de carga,
- $v_d$  : tensión de entrada de línea.

Para cada uno de estos puntos de funcionamiento, es posible obtener un modelo local lineal aproximado. A partir de la expresión general de la dinámica del sistema, según la relación [10]:

$$\mathbf{x}(k+1) = A_d(R, d)\mathbf{x}(k) + B_d(R, d)v_d(k) \quad (11)$$

donde el período de muestreo coincide con el ciclo de conmutación y el control se ejerce por medio de la modificación del ciclo de trabajo  $d(k)$ , se realiza la linealización entrada/salida según (3). Efectuando una adecuada selección de modelos locales, es posible construir un modelo borroso basado en modelos locales tal como el planteado en (4) y que tiene por expresión



**Figura 7.** Esquema de control propuesto.

$$R^i: \text{IF } v_o(k) \text{ is } V_o^i \text{ AND } R(k) \text{ is } R^i \text{ AND } v_d(k) \text{ is } V_d^i \text{ THEN} \\ \mathbf{x}(k+1) = \mathbf{x}_{0i} + \mathbf{A}_i(\mathbf{x}(k) - \mathbf{x}_{0i}) + \mathbf{B}_i(d(k) - d_{0i}) \quad (12)$$

En la figura 7 se muestra el esquema de control por selección de ganancia. El sistema borroso, a partir de la medida de los parámetros que determinan el régimen de trabajo, realiza el ajuste de ganancia de realimentación, según la base de reglas


$$R^j: \text{IF } v_o(k) \text{ is } V_o^j \text{ AND } R(k) \text{ is } R^j \text{ AND } v_d(k) \text{ is } V_d^j \text{ THEN} \\ d(k) = d_{0j} + \mathbf{K}(\mathbf{x}(k) - \mathbf{x}_{0j}) \quad (13)$$

La ley de control local se diseña en base a técnicas de control lineal óptimo cuadrático [6], obteniéndose un modelo en lazo cerrado similar al planteado en (7).

Por otra parte, la figura muestra cómo el punto de equilibrio correspondiente al objetivo de control, y en torno al cual se plantean los modelos locales, es estimado a su vez por la base de reglas borrosas, según:

$$R^i: \text{IF } v_o \text{ is } V_o^i \text{ AND } R \text{ is } R^i \text{ AND } v_d \text{ is } V_d^i \text{ THEN} \\ \mathbf{x}_0 = \mathbf{x}_{0i}, d_0 = d_{0i} \quad (14)$$

Como ejemplo de aplicación se tomará un convertidor de topología *buck* o reductora como el mostrado en la figura 8. Tras una selección óptima de la dimensión y del conjunto de modelos locales, según las técnicas de identificación presentadas en el apartado 2.2, se diseñan las leyes de control locales óptimas de manera que es posible asegurar su estabilidad global, al verificarse simultáneamente las




**Figura 9.** Convertidor de topología reductora.

relaciones (8) y (9).

Los resultados obtenidos son comparados con aquellos obtenidos en un diseño convencional de control en modo corriente [10] diseñado en torno al punto de trabajo nominal  $P(5,5,15)$ . La figura 9 muestra la evolución de la tensión de salida del convertidor, correspondiendo la línea continua al convertidor borroso propuesto, y la línea discontinua al control convencional en modo corriente. En primer lugar, se lleva al sistema al régimen de trabajo correspondiente a una tensión de referencia de 8 V., fuera de su punto nominal. A continuación

se realiza una variación periódica de la carga demandada de 5  $\Omega$  a 1  $\Omega$ . Puede observarse cómo la respuesta dada por el controlador convencional tiene una respuesta con importantes oscilaciones, traduciéndose estos picos en una tensión suministrada de baja calidad. El controlador propuesto, por su parte, es capaz de atenuar estas oscilaciones, ya que ajusta la ganancia del compensador a las nuevas condiciones de trabajo.

Cabe resaltar la sencillez de implementación en tiempo real del algoritmo de control diseñado, ya que éste se limita a la realización de una inferencia borrosa de la ganancia de control de realimentación.



**Figura 8.** Respuesta para variación de 5  $\Omega$  a 1  $\Omega$ .

## 5 Conclusiones

El modelado y control borroso basado en modelos locales se presenta como una alternativa válida para su aplicación a sistemas complejos, dando generalmente lugar a algoritmos de control de grandes prestaciones y de gran eficiencia en cuanto a su implementación.

El método de identificación propuesto para la obtención de modelos borrosos de caja negra y de caja gris es muy sensible a la existencia de ruido en los datos, no siendo extrapolables sus resultados a otros puntos de trabajo. Una forma de atenuar esta sensibilidad pasa por emplear como generador de datos sin ruido un modelo de caja blanca ajustado con los datos disponibles.

Actualmente se están estudiando soluciones alternativas para evitar los problemas causados por el ruido en los datos en el caso de la identificación. Otra línea de investigación pasa por la adición de algún esquema de adaptación a la base de reglas y a los propios modelos locales, así como el empleo de controladores locales robustos frente a la variación paramétrica en su región de validez.



## Referencias

- [1] Babuska R. *Fuzzy Modeling and Identification*. PhD dissertation, Delft University of Technology, Delft, The Netherlands, 1996.
- [2] Bastin G., Dochain D. *On-line Estimation and Adaptive Control of Bioreactors*. Ed. Elsevier, 1990.
- [3] Bezdek J. C. *Pattern recognition with Fuzzy Objective Function Algorithms*. Ed. Plenum Press, 1987.
- [4] Carbonell, P. *Técnicas de control borroso aplicadas a convertidores dc/dc conmutados. Aplicación al convertidor buck*. Tesis doctoral, Universidad Politécnica de Valencia, 1999.
- [5] Díez J. L., Navarro J. L. *Fuzzy Models of Complex Systems by means of Clustering Techniques*. Proc. 2<sup>nd</sup> Intelligent Systems in Control and Measurement, pp.147-153,1999.
- [6] Dorato, P., Abdallah, C., Cerone, V. *Linear Quadratic Control. An Introduction*. Englewood Cliffs (NJ): Prentice-Hall, 1995.
- [7] Emami M. R., Türksen I. B., Goldenberg A. A. "Development of a Systematic Methodology of Fuzzy Logic Modeling", *Transactions on Fuzzy Systems*, vol. 6, n°3, pp. 346-36, 1998.
- [8] Gustafson E. E., Kessel W. C. "Fuzzy Clustering with a Fuzzy Covariance Matrix", *IEEE CDC*, San Diego, California, pp. 761-766. 1979.
- [9] Johansen, T.A., Murray-Smith, R. "The operating regime approach to nonlinear modelling and control", en *Multiple Model Approaches to Modelling and Control*. Ed. R. Murray-Smith and T.A. Johansen, London: Taylor & Francis, 1997.
- [10] Kassakian, J.G., Schlecht, M.F., Verghese, G.C., *Principles of Power Electronics*, Nueva York : Addison-Wesley, 1991.
- [11] Romero J. A. *Identificación, Aplicando Técnica de Algoritmos Genéticos, del Proceso de Producción de  $\beta$ -glucosidasa por Fermentación Aeróbica*. Documento Interno del Departamento de Ingeniería de Sistemas y Automática, Universidad Politécnica de Valencia, 1999.
- [12] So, W.C., Tse. K., Lee, Y.S. "An experimental fuzzy controller for dc-dc converters", *Proc. IEEE Power Electronics Specialists Conference and Exposition*, vol 2, pp. 1339-1345, Atlanta, 1995.
- [13] Sugeno M., Yasukawa T. "A Fuzzy-Logic-Based Approach to Qualitative Modeling". *Transactions on Fuzzy Systems*, vol. 1, n°1, pp. 7-31, 1993.
- [14] Tanaka, K., Sugeno, M. "Stability analysis and design of fuzzy control systems" *Fuzzy Sets and Systems* vol. 45, pp. 135-156, 1992.
- [15] Verbruggen H. B., Babuska R. *Fuzzy Logic Control: Advances in Applications*. pp. 205-226. Ed. World Scientific, 1999.
- [16] Wang, L.X., Mendel, J.M. "Fuzzy basis functions, universal approximation, and orthogonal least-squares learning," *IEEE Trans. Neural Networks*, vol. 3, pp. 807-814, 1992.