

## MONOGRAFÍA: COMPUTACIÓN EVOLUTIVA

### Modelado cualitativo utilizando una metodología evolutiva de aprendizaje iterativo de bases de reglas difusas

O. Cordon<sup>1</sup>, M.J. del Jesus<sup>2</sup>, F. Herrera<sup>1</sup>, M. Lozano<sup>1</sup>

<sup>1</sup> Dpto. de Ciencias de la Computación e Inteligencia Artificial  
E.T.S.I. Informática. Universidad de Granada. Granada (España)  
e-mail: ocordova, herrera, lozano@decsai.ugr.es

<sup>2</sup> Dpto. de Informática  
Escuela Politécnica Superior. Universidad de Jaén. Jaén (España)  
e-mail: mjj@apolo.ujaen.es

#### Resumen

En este trabajo repasamos los aspectos básicos de MOGUL (Methodology to Obtain Genetic fuzzy rule-based systems Under the iterative rule Learning approach), una metodología evolutiva de aprendizaje de Bases de Reglas Difusas, y presentamos un Sistema Basado en Reglas Difusas Evolutivo concreto, obtenido a partir de la misma, que permite resolver problemas de modelado cualitativo. Con objeto de estudiar su comportamiento, lo empleamos en la resolución de un problema real, la valoración de la calidad del arroz cocido, y lo compararemos con otros métodos de modelado cualitativo con distintas características.

**Palabras Clave:** Sistemas Basados en Reglas Difusas, Modelado Cualitativo, Aprendizaje Evolutivo Inductivo, Sistemas Basados en Reglas Difusas Evolutivos.

#### 1. Introducción

En la actualidad, una de las áreas de aplicación más importantes de la Teoría de Conjuntos Difusos, propuesta por Zadeh en 1965 [1], la componen los Sistemas Basados en Reglas Difusas (SBRDs). Este tipo de sistemas constituyen una extensión de los Sistemas Basados en Reglas Clásicas, puesto que emplean reglas difusas en lugar de reglas de la Lógica Clásica. Debido a esta razón, se han aplicado con éxito a una amplia gama de problemas en los que están presentes, en distintas formas, la vaguedad y la incertidumbre [2, 3, 4].

Dentro de estas aplicaciones, podemos destacar dos grandes campos: el control difuso [3] y el modelado difuso de sistemas [4]. Este último se puede considerar como una vía para modelar un sistema haciendo uso de un lenguaje de descripción basado en Lógica Difusa con predicados difusos [5]. La Lógica Difusa posee herramientas

que permiten obtener distintos tipos de modelos difusos se según desee que predomine la interpretabilidad, *modelado cualitativo*, o la precisión, *modelado difuso*, en los mismos [5].

Es necesario llevar a cabo distintas tareas de diseño para obtener un SBRD capaz de resolver un problema concreto. Podemos agrupar estas tareas en dos grandes grupos: la elección de los operadores difusos que se emplearán para realizar el proceso de inferencia y la obtención de una Base de Reglas Difusas (BRD) que represente el conocimiento sobre el modo en que se resolverá el problema en cuestión.

La primera tarea de diseño se ha estudiado en profundidad en la literatura especializada, habiéndose efectuado una gran cantidad de estudios teóricos y comparativos para abordar el problema de seleccionar la mejor combinación de operadores posible en el proceso de razonamiento difuso [6, 7].

La segunda, en cambio, suele ser más difícil de realizar ya que la composición de la BRD depende directamente del problema a resolver. En los últimos años, se han presentado una gran cantidad de métodos basados en el uso de Algoritmos Evolutivos (AEs) [8], habitualmente Algoritmos Genéticos (AGs) [9], para generar o refinar la definición de la BRD de un modo automático. Este conjunto de procesos constituyen los denominados Sistemas Basados en Reglas Difusas Evolutivos (SBRDEs) [10], los cuales están en auge en los últimos años (véase [11]).

De este modo, se han desarrollado una gran cantidad de procesos evolutivos de aprendizaje automático que tratan de resolver el problema haciendo uso de la información numérica disponible. Aún así, gran parte de estos procesos presentan una serie de inconvenientes tales como el hecho de que no aprovechan la información experta disponible o que solamente permiten el diseño de un tipo concreto de SBRD.

Debido a estas razones, parece adecuado el desarrollo de una metodología más general que permitiera la generación automática de la BRD en el caso en el que ésta no pudiera ser obtenida directamente a partir de la información experta existente. Esta metodología debería posibilitar la creación de SBRDEs que permitieran diseñar SBRDs de todos los tipos existentes y que aprovecharan la información experta disponible para mejorar la definición de la BRD. Además, debería establecer una estructura genérica y una serie de recomendaciones de diseño que fueran, a la vez, lo suficientemente flexibles como para que fuera sencillo construir procesos concretos de aprendizaje a partir de éstas y lo suficientemente robustas como para que dichos procesos permitieran el diseño de SBRDs con el mejor comportamiento posible.

En [12, 13] presentamos MOGUL, una metodología evolutiva de aprendizaje de BRDs que satisfice los objetivos comentados. En este trabajo, además de repasar brevemente las características principales de esta metodología, introduciremos un SBRDE concreto, obtenido a partir de la misma, que permitirá resolver problemas de modelado cualitativo y mostraremos su aplicación a un problema concreto, la valoración de la calidad del arroz cocido.

La estructura del artículo es la siguiente. En la Sección 2 se presenta una breve descripción de MOGUL. En la Sección 3 se describe el SBRDE para tareas de modelado cualitativo. En la Sección 4, se analiza el comportamiento de éste en la aplicación comentada, comparándolo con otros procesos de diseño de SBRDs con distintas características. Finalmente, en la Sección 5 se muestran las principales conclusiones obtenidas.

## 2. MOGUL: Una Metodología para el Diseño Automático de SBRDEs Mediante AEs

A continuación describimos brevemente los aspectos básicos de MOGUL. Para una descripción más detallada de la metodología véase [12, 13]:

- Permite diseñar distintos de SBRDs: de tipo Mamdani (descriptivos, aproximativos restringidos y aproximativos no restringidos) y de tipo TSK.

- Hace uso de la mayor cantidad posible del conocimiento disponible para generar la BRD. Este conocimiento, sea experto o numérico, puede ser incorporado directamente en el proceso de aprendizaje trabajando de varias formas distintas.

- MOGUL se basa en el enfoque de Aprendizaje Iterativo de Reglas (AIR) [14]. Este enfoque trata de resolver el problema del aprendizaje en dos etapas: *generación y postprocesamiento*, la primera de ellas dedicada a fomentar la competición entre reglas individuales y la segunda a fomentar una buena cooperación entre las reglas generadas para obtener una BRD con buen comportamiento global.

Los SBRDEs construidos a partir de MOGUL extienden esta forma de trabajo de dos formas con objeto de mejorar la calidad de las BRDs aprendidas:

- Por un lado, algunos de ellos incorporan la cooperación entre reglas en la primera etapa del aprendizaje.
- Por otro, prácticamente todos descomponen la etapa de postprocesamiento en dos subprocesos: el de *multisimplificación*, encargado de generar distintas definiciones simplificadas de la BRD generada en la primera etapa, y el de *ajuste*, que refina los parámetros empleados en las reglas de cada una de ellas (funciones de pertenencia y parámetros de los consecuentes, en el caso de SBRDs TSK) para devolver la aprendida finalmente.

De este modo, todos ellos presentan la misma estructura genérica compuesta por las tres etapas comentadas (excepcionalmente, solo por dos). Para obtener un SBRDE concreto, el usuario únicamente habrá de diseñar cada una de ellas verificando unos requisitos generales.

- Con objeto de mejorar el comportamiento de los SBRDs diseñados, se exige que las BRDs generadas verifiquen una serie de propiedades tales como las de *completitud y consistencia*, además de presentar un buen grado de cubrimiento de

ejemplos. Para las expresiones de estas propiedades, véase [13, 15].

• Por último, en MOGUL hemos considerado distintos factores para reducir la complejidad del espacio de búsqueda manejado por los AEs que implementan cada etapa y para producir una exploración y explotación adecuadas sobre él, con objeto de que el proceso de búsqueda sea eficaz. Entre otros: elección de un esquema de representación que codifique el máximo de información posible y diseño de operadores específicos que establezcan un buen equilibrio entre la exploración y la explotación del espacio de búsqueda.

### 3. Un SBRDE para Modelado Cualitativo Basado en MOGUL

En esta Sección, vamos a analizar un SBRDE concreto que puede ser empleado para resolver problemas de modelado cualitativo. Este tipo de modelado se lleva a cabo por medio de los SBRDs descriptivos de tipo Mamdani, los cuales emplean la siguiente estructura de regla:

SI  $X_1$  es  $A_1$  y ... y  $X_n$  es  $A_n$   
ENTONCES  $Y$  es  $B$ .

donde  $X_1, \dots, X_n$  y  $Y$  son las variables lingüísticas de entrada y salida, respectivamente, y  $A_1, \dots, A_n$  y  $B$  son etiquetas lingüísticas con un conjunto difuso asociado que define su semántica. Las reglas en sí están contenidas en un componente de la BRD denominado Base de Reglas (BR), mientras que las etiquetas lingüísticas y las funciones de pertenencia se almacenan en otro denominado Base de Datos (BD).

El proceso evolutivo de aprendizaje que presentamos está compuesto por las tres etapas siguientes [16]:

• Un proceso iterativo de generación de reglas lingüísticas a partir de ejemplos, formado por dos componentes: un método de generación de reglas difusas basado en un algoritmo inductivo no evolutivo y un método iterativo de cubrimiento del conjunto de ejemplos.

• Un proceso genético de multisimplificación para llevar a cabo la selección de reglas; el cual se implementa por medio de un AG con codificación binaria que emplea una función de comparación genotípica y una medida del rendimiento del SBRD codificado en el cromosoma. Como ya hemos comentado en la Sección anterior, este proceso permite obtener varias definiciones de la BRD formadas por las distintas combinaciones de las reglas lingüísticas generadas en la fase anterior que mejor van de cooperación presentan.




Figura 1: Ejemplo de partición difusa

• Un proceso genético de ajuste basado en un AG con codificación real y en una función de adaptación que considera dos criterios: una medida del rendimiento del SBRD codificado en el cromosoma y una función que penaliza la no satisfacción de la propiedad de completitud. Este último proceso proporciona la BRD aprendida, ajustando la definición previa de la forma de las funciones de pertenencia que especifican la semántica de los términos lingüísticos existente en la BD. La BRD que mejor comportamiento presente tras el ajuste, de entre todas las generadas en la segunda etapa, será la devuelta como salida final por el SBRDE.

En las subsecciones siguientes describimos brevemente cada una de las etapas del aprendizaje.

#### 3.1. El Proceso Iterativo de Generación de Reglas Lingüísticas

El proceso de generación se basa en una definición inicial de la BD, compuesta por una serie de particiones difusas de los espacios en los que se define cada variable lingüística. La Figura 1 muestra un ejemplo de una partición difusa de este tipo.

El método de cubrimiento es un proceso iterativo que permite obtener un conjunto de reglas difusas que representan el conocimiento existente en el conjunto de ejemplos. En cada iteración, se ejecuta el método de generación, el cual proporciona la mejor regla difusa de acuerdo al estado actual del conjunto de ejemplo, se considera el cubrimiento relativo que dicha regla provoca sobre éste y se eliminan aquellos ejemplos cubiertos a un grado mayor o igual que  $\epsilon$ , valor proporcionado por el diseñador del SBRD. El método finaliza cuando no quedan ejemplos en el conjunto de entrenamiento.

Cada vez que se ejecuta el método de generación, se construye un conjunto de reglas candidatas generando la regla que mejor cubre a cada ejemplo del conjunto. En ese momento, se selecciona la mejor regla de ese conjunto de acuerdo a los valores de función de selección multicriterio. Esta función está compuesta por tres criterios frecuentistas que analizan el cubrimiento

que cada regla produce sobre el conjunto de entrenamiento. Las expresiones de estos criterios pueden ser consultadas en [16].

### 3.2. El Proceso Genético de Multi-simplificación

Puesto que el proceso de generación trabaja de un modo iterativo, puede ocurrir que la BRD obtenida contenga reglas redundantes que no cooperen adecuadamente. El propósito de esta segunda etapa es simplificar la BRD previa, eliminando de la misma estas reglas.

La característica principal de este proceso es su capacidad para generar varias definiciones simplificadas distintas del conjunto de reglas difusas anterior. Para ello, se ejecuta el proceso genético de simplificación propuesto en [17]. Dicho proceso está basado en un AG con codificación binaria que codifica el conjunto de reglas obtenido en el proceso de generación en un cromosoma, representando un 1 la presencia de la regla en cuestión en la BRD final y un 0 su ausencia. Los operadores genéticos empleados son el cruce en dos puntos y la mutación aleatoria y el mecanismo de selección es el muestreo universal estocástico, combinado con un esquema elitista. La función de adaptación combina una medida de error, el error cuadrático medio (EC), y un criterio que penaliza la no satisfacción de la propiedad de completitud por parte de la BRD codificada.

Cada vez que el proceso genético de simplificación genera una definición simplificada de la BRD, el de multisimplificación penaliza la zona del espacio de búsqueda en la que se encuentra dicha solución para no generarla en ejecuciones posteriores. El esquema de compartición genotípico se emplea para penalizar los individuos de acuerdo a su proximidad espacial a las soluciones previamente encontradas. El proceso finaliza cuando se ha generado el número deseado de BRDs simplificados.

Para una descripción más completa de este proceso, véase [18].

### 3.3. El proceso Genético de Ajuste

El proceso genético de ajuste se basa en un AG con codificación real que codifica una definición distinta de la BD en cada cromosoma [16]. Cada partición difusa primaria (véase la Figura 1) se representa por medio de un vector formado por  $3 \cdot N_i$  valores reales, donde  $N_i$  representa el número de términos que componen el conjunto de términos asociados a la variable lingüística  $i$ . La BD completa (para un problema con  $m$  variables lingüísticas), se codifica en un cromosoma real de longitud fija,  $C_j$ , uniendo las representaciones

parciales de cada una de las particiones difusas de las variables del siguiente modo:

$$C_j = (a_{11}, b_{11}, c_{11}, \dots, a_{1N}, b_{1N}, c_{1N}), \\ C_j = C_{j1} C_{j2} \dots C_{jm}$$

Las particiones difusas iniciales se emplean para definir el intervalo de ajuste  $[c_{1h}^i, c_{2h}^i]$  asociado a cada gen  $c_h$  de  $C_j$ ,  $h = 1 \dots \sum_{i=1}^m N_i \cdot 3$ . El operador de cruce max-min-aritmético y el de mutación no uniforme de Michalewicz se emplean para alterar la composición de los individuos y la selección se lleva a cabo de la misma forma que en el proceso genético de simplificación. La función de adaptación es también la misma que en dicho proceso.

Por otro lado, la definición inicial de la BD también se emplea para generar la población inicial. Dicha BD se codifica directamente en un cromosoma, notado como  $C_1$ . Los individuos restantes se generan aleatoriamente haciendo uso de los intervalos de ajuste asociados a cada función de pertenencia.

## 4. Ejemplo: Valoración de la Calidad del Arroz Cocido

La valoración subjetiva de la calidad de las comidas es un problema muy importante pero, a la vez, muy difícil. En el caso de la valoración de la calidad del arroz cocido, se suele llevar a cabo mediante un tipo de valoración subjetiva denominado *prueba sensorial*. En esta prueba, un grupo de expertos, habitualmente formado por 24 personas, proceden a dar su evaluación en función de una serie de características asociadas a cada tipo de arroz. Dichas características son: *Sabor*, *Aspecto*, *Gusto*, *Grado de pegajosidad* y *Dureza* [19].

Debido a la gran cantidad de variables relevantes, el problema de la valoración de la calidad del arroz se hace muy complejo, lo que justifica la necesidad de afrontar un modelado que permita determinar la relación no lineal existente en el mismo. Además, el objetivo no es únicamente el conseguir un modelo preciso, sino también que dicho modelo pueda aportar alguna información sobre el proceso de razonamiento que lleva a cabo el experto humano para evaluar un tipo de arroz de una forma concreta. Por todas estas razones, en esta sección nos planteamos la obtención de un modelo cualitativo que nos permita resolver el problema planteado.

Para ello, vamos a emplear el conjunto de datos presentado en [19]. Este conjunto está compuesto por 105 vectores de datos que recogen valoraciones subjetivas de las seis variables en cuestión (las cinco comentadas y la valoración

Tabla 1: Resultados obtenidos en la valoración de la calidad del arroz

N. et.	D1			D2			D3		
	#R	EC <sub>entr</sub>	EC <sub>prue</sub>	#R	EC <sub>entr</sub>	EC <sub>prue</sub>	#R	EC <sub>entr</sub>	EC <sub>prue</sub>
2	32	0.00862	0.00985	15	0.00110	0.00213	6	0.00107	0.00237
3	243	0.00251	0.00322	23	0.00073	0.00460	10.5	0.00069	0.00301
4	1024	0.00133	0.00208	29.5	0.00089	0.00272	20.5	0.00087	0.00273
5	3125	0.00082	0.00210	42.9	0.00044	0.01440	37.3	0.00042	0.01061

global del tipo de arroz), efectuadas por expertos sobre otros tantos tipos de arroz cultivados en Japón (como por ejemplo el Sasanishiki, el Akita-Komachi, etc.). Las seis variables están normalizadas, por lo que toman valores en el intervalo real [0, 1].

Con objeto de evitar cualquier tipo de sesgo en el aprendizaje, hemos obtenido aleatoriamente diez particiones distintas del conjunto comentado, compuestas por 75 datos en el conjunto de entrenamiento y 30 en el de prueba, para generar diez modelos cualitativos en cada experimento. Para resolver el problema, consideraremos, además del SBRDE presentado en este trabajo, dos procesos de modelado cualitativo con distintas características:

- D1. El proceso inductivo de aprendizaje de Nozaki et al. presentado en [19].
- D2. Un SBRDE en dos etapas compuesto por el algoritmo de Wang y Mendel [20] y el proceso genético de ajuste de BRDs introducido en la sección 3.3..
- D3. El SBRDE presentado en este trabajo.

Tal como se hacía en [19], hemos considerado las mismas particiones difusas para las seis variables manejadas. Dichas particiones se han obtenido mediante un proceso de normalización en el que se ha dividido sucesivamente el universo de discurso de cada variable en 2, 3, 4 y 5 partes iguales, y se ha asociado a cada una de ellas un conjunto difuso triangular.

Los resultados obtenidos en la experimentación realizada están recogidos en la tabla 1, en la que *N. et.* representa el número de etiquetas considerado en las particiones difusas de las seis variables. Los valores contenidos en las columnas *EC<sub>entr</sub>* y *EC<sub>prue</sub>* han sido calculados haciendo la media de los errores cuadráticos cometidos por los diez modelos cualitativos generados en cada caso en la aproximación de los conjuntos de entrenamiento y prueba, respectivamente. La columna notada por #R contiene el número medio de reglas que componen las BRDs de dichos modelos.

A la vista de estos resultados podemos concluir que el proceso de aprendizaje de Nozaki, D1, ha obtenido el mejor resultado en lo que respecta al nivel de generalización (0.00208 en la medida de EC sobre el conjunto de prueba al trabajar con 4 etiquetas). Desafortunadamente, este resultado no nos es útil en la práctica ya que el número de reglas que presentan las BRDs de los modelos generados a partir de este método (32, 243, 1024 o 3124) es excesivo para permitir que el modelo obtenido sea interpretable. Recordemos que el objetivo que se perseguía en esta aplicación no era únicamente obtener un modelo con buen rendimiento, sino conseguir que dicho modelo fuera interpretable por el ser humano.

Debido a esta razón, el SBRDE propuesto se presenta como un método muy apropiado para resolver el problema ya que, además de presentar resultados similares a los del proceso D2 (0.00042 contra 0.00044 en la aproximación del conjunto de entrenamiento y 0.00237 frente a 0.00213 en el de prueba), es el que consigue generar modelos más simples (con menos reglas) y, por tanto, más fáciles de interpretar.

Si siguiendo estos criterios, los modelos más adecuados para resolver el problema serían los generados a partir de nuestro SBRDE al trabajar con 2 etiquetas ya que, en ese caso, los resultados medios son de 0.00107 en el EC sobre el conjunto de entrenamiento y 0.00237 en el de prueba, y las BRDs de los diez modelos generados están compuestas únicamente por 6 reglas.

En la tabla 2 mostramos, a modo de ejemplo, la composición de la BRD de uno de esos modelos. Los valores concretos obtenidos por el mismo en ambas medidas son: *EC<sub>entr</sub>* = 0.00138 y *EC<sub>prue</sub>* = 0.00116.

## 5. Conclusiones

En este trabajo hemos repasado los aspectos básicos de MOGUL, una metodología evolutiva de aprendizaje de BRDs, además de introducir un SBRDE concreto, obtenido a partir de la misma, que permite resolver problemas de modelado cualitativo. Hemos mostrado también su aplicación

Tabla 2: BRD de un modelo cualitativo generado por el SBRDE D3 con 2 etiquetas

	Sabor	Aspecto	Gusto	Pegajosidad	Dureza	Valoración
R <sub>1</sub> :	Bueno	Bueno	Bueno	Pegajoso	Blando	Alta
R <sub>2</sub> :	Bueno	Bueno	Bueno	Pegajoso	Blando	Alta
R <sub>3</sub> :	Bueno	Bueno	Bueno	Pegajoso	Blando	Alta
R <sub>4</sub> :	Bueno	Malo	Malo	No pegajoso	Duro	Baja
R <sub>5</sub> :	Malo	Malo	Malo	No pegajoso	Duro	Baja
R <sub>6</sub> :	Malo	Bueno	Bueno	Pegajoso	Blando	Baja

a un problema específico, la valoración de la calidad del arroz cocido, comparándolo con otros procesos de diseño de SBRDs de tipo Mamdani con distintas características. El SBRDE ha obtenido muy buenos resultados mostrando el buen comportamiento de la metodología.

**Agradecimientos:** Este trabajo ha sido financiado por la CICYT dentro del proyecto TIC96-0778.

## Referencias

- [1] Zadeh L.A. (1965). Fuzzy sets. *Information and Control*, 8, 338-353.
- [2] Bardossy A. y Duckstein L. (1995). *Fuzzy rule-based modeling with application to geophysical, biological and engineering systems*. CRC Press.
- [3] Driankov D., Hellendoorn H. y Reinfrank M. (1993). *An introduction to fuzzy control*. Springer-Verlag.
- [4] Pedrycz W. (Ed) (1996). *Fuzzy modelling. Paradigms and practice*. Kluwer Academic.
- [5] Sugeno M. y Yasukawa T. (1993). A fuzzy-logic-based approach to qualitative modeling. *IEEE Transactions on Fuzzy Systems*, 1(1), 7-31.
- [6] Cerdón O., Herrera F. y Peregrín A. (1997). Applicability of the fuzzy operators in the design of fuzzy logic controllers. *Fuzzy Sets and Systems*, 86, 15-41.
- [7] Cerdón O., Herrera F. y Peregrín A. (1998). Searching for basic properties obtaining robust implication operators in fuzzy control. *Fuzzy Sets and Systems* (por aparecer).
- [8] Bäck T. (1996). *Evolutionary algorithms in theory and practice*. Oxford University Press.
- [9] Goldberg D.E. (1989). *Genetic algorithms in search, optimization, and machine learning*. Addison-Wesley, New York.
- [10] Cerdón O. y Herrera F. (1995). A general study on genetic fuzzy systems. En: J. Periaux, G. Winter, M. Galán, P. Cuesta (Eds.), *Genetic Algorithms in Engineering and Computer Science*. John Wiley and Sons, 33-57.
- [11] Cerdón O., Herrera F. y Lozano M. (1997). On the combination of fuzzy logic and evolutionary computation: a short review and bibliography. En: W. Pedrycz (Ed.), *Fuzzy Evolutionary Computation*. Kluwer Academic Press, 57-77.
- [12] Cerdón O., del Jesus M.J., Herrera F. y Lozano M. (1997). Una metodología evolutiva para el diseño automático de sistemas basados en reglas difusas mediante algoritmos evolutivos. En: *Actas del Seminario sobre Computación Evolutiva: Teoría y Aplicaciones. Séptima Conferencia de la Asociación Española para la Inteligencia Artificial*, 1-12. Málaga (España).
- [13] Cerdón O., del Jesus M.J., Herrera F. y Lozano M. (1998). MOGUL: A methodology to obtain genetic fuzzy rule-based systems under the iterative rule learning approach. *Informe técnico DECSAI-98101*. Dpto. Ciencias de la Computación e Inteligencia Artificial. Universidad de Granada (España).
- [14] González A. y Herrera F. (1997). Multi-stage genetic fuzzy systems based on the iterative rule learning approach. *Mathware & Soft Computing*, 4, 233-249.
- [15] González A. y Pérez R. (1998). Completeness and consistency conditions for learning fuzzy rules. *Fuzzy Sets and Systems* (por aparecer).
- [16] Cerdón O. y Herrera, F. (1997). A three-stage evolutionary process for learning descriptive and approximative fuzzy logic controller knowledge bases from examples. *International Journal of Approximate Reasoning*, 17(4), 369-407.
- [17] Herrera F., Lozano M. y Verdegay J.L. (1998). A learning process for fuzzy control rules using genetic algorithms. *Fuzzy Sets and Systems* (por aparecer).
- [18] Cerdón O. y Herrera, F. (1997). Hybridizing genetic algorithms with sharing scheme and evolution strategies for designing approximate fuzzy rule-based systems. *Informe técnico DECSAI-96126*. Dpto. Ciencias de la Computación e Inteligencia Artificial. Universidad de Granada. Granada (España).
- [19] Nozaki K., Ishibuchi H. y Tanaka H. (1997). A simple but powerful heuristic method for generating fuzzy rules from numerical data. *Fuzzy Sets and Systems*, 86, 251-270.
- [20] Wang L.X. y Mendel J.M. (1992). Generating fuzzy rules by learning from examples. *IEEE Transactions on Systems, Man, and Cybernetics*, 22(6), 1414-1427.