

APRENDIZAJE EVOLUTIVO COOPERATIVO DE REGLAS Y OPERADORES PARA SISTEMAS DIFUSOS LINGUISTICOS

F. Herrera

Dpto. Ciencias de la Computación e I.A.
Universidad de Granada
18071-Granada
herrera@decsai.ugr.es

F. A. Márquez

Depto. Ingeniería Electrónica
Sistemas Informáticos y A.
Universidad de Huelva
21071-Huelva
alfredo.marquez@diesia.uhu.es

A. Peregrín

Depto. Ingeniería Electrónica,
Sistemas Informáticos y A.
Universidad de Huelva
21071-Huelva
peregrin@diesia.uhu.es

Resumen

Este trabajo¹ presenta un modelo evolutivo que aprende de forma simultánea la Base de Reglas y los parámetros de los operadores difusos parametrizados de conjunción y defuzzificación, con el propósito de obtener un mayor nivel de cooperación entre la Base de Conocimiento y los operadores difusos. Con objeto de mostrar las mejoras en cuanto a precisión que se obtienen con este modelo, se comprueban sus resultados empíricamente en una aplicación.

Palabras Clave: Modelado Difuso, Métodos de Defuzzificación Adaptativos, Sistema de Inferencia Adaptativo, Aprendizaje Cooperativo de Reglas.

1 INTRODUCCIÓN

Interpretabilidad y precisión son dos requerimientos generalmente contradictorios en el diseño de Modelos Difusos (MD). La interpretabilidad es la capacidad de expresar el comportamiento del sistema real de una forma entendible. La precisión es la capacidad de representar fielmente el comportamiento del sistema real. En el diseño de MD existe una línea de trabajo que trata de buscar un balance entre precisión e interpretabilidad, lo que ha producido creciente interés en su estudio [3, 4].

Dos son las tareas fundamentales en el diseño de sistemas difusos lingüísticos para una aplicación concreta: la obtención de la Base de Conocimiento (BC), y la selección de los operadores del Sistema de Inferencia y la Interfaz de Defuzzificación. Estos últimos, en el marco del equilibrio entre precisión e interpretabilidad, han alcanzado recientemente mayor importancia. El uso de

operadores parametrizados tanto en el sistema de inferencia [1] como en la interfaz de defuzzificación [10], o en ambos de modo simultáneo [14] ha demostrado ofrecer mejoras importantes en la precisión para cada aplicación.

Los Algoritmos Genéticos (AGs) han demostrado ser una herramienta valiosa en éste ámbito, tanto para el ajuste evolutivo de los citados parámetros como para el de la BC. En este trabajo se propone el aprendizaje de los operadores parametrizados junto con el aprendizaje de la Base de Reglas (BR) en un mismo modelo evolutivo.

Para la BR se ha escogido la metodología COR [5], que consiste en un método de aprendizaje guiado por ejemplos, y que a diferencia de la mayoría de ellos, no trata de obtener el mejor consecuente para cada regla considerada aisladamente, sino el conjunto de ellas que mejor cooperan. El modelo evolutivo completo, reglas y operadores, utiliza un sólo cromosoma.

Este trabajo se ha organizado de la siguiente forma: En la Sección 2 se introducen los operadores difusos adaptativos, para introducir en la Sección 3 la propuesta del modelo evolutivo cooperativo. La Sección 4 contiene el estudio experimental desarrollado, que incluye el estudio estadístico, y finalmente una Sección con las conclusiones.

2 OPERADORES DIFUSOS ADAPTATIVOS

En esta sección se describe la notación utilizada para los Sistemas Basados en Reglas Difusas (SBRDs), así como en la primera subsección el operador de conjunción y en la segunda el método de defuzzificación adaptativos utilizados.

2.1. OPERADOR DE CONJUNCIÓN ADAPTATIVO

Los SBRDs para modelado utilizan reglas SI - ENTONCES de a forma siguiente:

¹ Soportado por el MEC bajo el Proyecto TIN2005-08386-C05-01.

$R_i: \text{Si } X_{i1} \text{ es } A_{i1} \text{ y } \dots \text{ y } X_{im} \text{ es } A_{im} \text{ entonces } Y \text{ es } B_i$

con $i = 1$ hasta N reglas, siendo X_{i1} hasta X_{im} las entradas e Y la salida, y con A_{i1} hasta A_{im} y B_i los antecedentes y consecuentes respectivamente.

La expresión de la Regla Composicional de Inferencia en el modelado difuso con fuzzificación puntual es mostrada en la expresión (1), donde μ_B es la función de pertenencia del consecuente inferido, I es el operador de implicación, C el operador de conjunción, μ_{A_i} al tratarse de fuzzificación puntual son los puntos de corte de las entradas discretas (x_1, \dots, x_n) del sistema con las funciones de pertenencia de los antecedentes de las reglas, y μ_B el consecuente de la regla.

$$\mu_B(y) = I(C(\mu_{A_1}(x_1), \dots, \mu_{A_n}(x_n)), \mu_B(y)), \quad (1)$$

Por tanto, el sistema de inferencia emplea dos operadores: el de conjunción, $C(\cdot)$ para calcular el grado de emparejamiento, y el de implicación, $I(\cdot)$ para calcular a continuación el consecuente inferido.

En [1 y 13] se estudiaron las diferentes formas de parametrización del Sistema de Inferencia observándose menor influencia en el uso de operadores de implicación adaptativos frente al de los de conjunción. Por este motivo, en este trabajo se utiliza la parametrización del Sistema de Inferencia exclusivamente mediante el operador de conjunción.

Las T-normas son una familia de operadores generalmente usados en el diseño de MD, modelando tanto el operador de conjunción como el de implicación [12] y ofreciendo buen comportamiento [9]. En este trabajo utilizaremos la t-norma parametrizada de Dubois (2) por ser computacionalmente eficiente, y ofrecer un comportamiento entre la del mínimo y la del producto algebraico, las cuales son las que mejores resultados ofrecen [7]. Otras t-normas parametrizadas pueden encontrarse en [16].

$$\text{Dubois} \quad T_{\text{Dubois}}(x, y, \alpha) = \frac{x \cdot y}{\text{Max}(x, y, \alpha)} \quad (2)$$

$(0 \leq \alpha \leq 1)$

El operador de conjunción adaptativo modula la influencia del grado de emparejamiento atenuándolo o acentuándolo. Esta modificación es no lineal debido a la expresión de la t-norma parametrizada.

Dos modelos de conjunción adaptativa podrían considerarse dependiendo de si se utiliza un sólo parámetro α , o distintos parámetros α_i para cada regla. Un sólo parámetro permite ajustar globalmente el comportamiento del conector mientras que los parámetros individuales ajustan dicho comportamiento para cada regla de la BC. El modelo de un sólo parámetro ofrece peores resultados [1], por lo que en este trabajo se

utiliza el modelo con un parámetro para cada regla. La t-norma de Dubois actúa como la del mínimo cuando $\alpha = 0$, mientras que cuando $\alpha = 1$ lo hace como la del producto. Cuando $0 < \alpha < 1$ continúa comportándose como el mínimo salvo cuando todos los cruces con los antecedentes se encuentran por debajo de α , tomando valores entre el mínimo y el producto, y provocando un efecto similar al conocido mecanismo de concentración [15], que consiste en alterar el significado lingüístico de la estructura de la regla modificando el significado de la etiqueta. Por tanto, la t-norma parametrizada de Dubois conecta con el mínimo en aquellos casos en los que los cruces con los antecedentes son más significativos, mientras que los demás los lleva a cabo con un valor comprendido entre el mínimo y el producto.

2.2. MÉTODO DE DEFUZZIFICACIÓN ADAPTATIVO

La expresión formal (3) se emplea generalmente para generar métodos de defuzzificación adaptativos,

$$y_0 = \frac{\sum_i f(h_i) \cdot V_i}{\sum_i f(h_i)}, \quad (3)$$

donde h_i es el grado de emparejamiento, $f(h_i)$ es un término funcional del grado de emparejamiento y V_i es el máximo valor (MV_i) o el centro de gravedad (CG_i). Se trata de la expresión de un método de defuzzificación que actúa en Modo B, es decir, primero defuzzifica la aportación individual de la inferencia obtenida con cada regla y posteriormente se computa una suma ponderada.

El término funcional puede utilizar un solo parámetro β , o bien un parámetro por cada regla de la BC, β_i , que es la opción utilizada en este trabajo por obtener mejores resultados [10]. Por otro lado, el término funcional puede ser de tipo producto o potencia, como se muestra en las expresiones (4) y (5).

$$f(h_i) = h_i \cdot \beta_i, \quad f(h_i) = h_i^{\beta_i}. \quad (4), (5)$$

La combinación de estos dos funcionales con el MV o el CG genera cuatro métodos de defuzzificación.

El empleo del funcional de tipo potencia mediante un parámetro para cada regla es equivalente a una de las técnicas empleadas para realizar la modificación lingüística de la estructura de la regla [15]. Por otro lado, el funcional de tipo producto tiene un efecto equivalente al empleo de reglas con pesos [6]. El siguiente ejemplo presenta un conjunto de reglas con pesos, donde éstos son denominados por w_i :

*Si X_{11} es A_{11} y... y X_{1n} es A_{1n} entonces Y es B_1 con w_1
Si X_{21} es A_{21} y... y X_{2n} es A_{2n} entonces Y es B_2 con w_2*

Si X_{n1} es A_{n1} y... y X_{nm} es A_{nm} entonces Y es B_n con w_n

En este trabajo se ha seleccionado el funcional de tipo producto, con un parámetro para cada regla, y utilizando CG, cuya expresión se muestra en (6).

$$y_0 = \frac{\sum_{i=1}^N h_i \cdot \beta_i \cdot CG_i}{\sum_{i=1}^N h_i \cdot \beta_i} \quad (6)$$

Este método de defuzzificación es equivalente al conocido WECO cuando los parámetros se igualan a la unidad.

3. MODELO EVOLUTIVO COOPERATIVO DE APRENDIZAJE

Como se ha citado con anterioridad, la metodología COR (reglas que cooperan) [5] es un método *ad hoc* guiado por ejemplos, que proporciona conjuntos de reglas particularmente precisas dado que no selecciona la mejor regla individual en cada caso sino que prefiere aquellas que en conjunto, ofrezcan una BC con un mejor comportamiento global.

Este método manja un conjunto de etiquetas de consecuentes, uno para cada regla, obteniendo la BR como un problema de optimización combinatoria.

En este trabajo utilizamos también el conocido método de Wang y Mendel (WM) [17], como un método de aprendizaje con el que comprar el método cooperativo presentado, al que se le ajustan posteriormente los parámetros de la conjunción y la defuzzificación.

El modelo presentado trata de mejorar la precisión del modelo difuso, utilizando la cooperación entre la BR y los operadores difusos.

Para ello, se ha utilizado un modelo evolutivo basado en un Algoritmo Genético (AG) de tipo CHC [11] cuyo cromosoma tiene un esquema de codificación triple ($CS_{COR} + CS_C + CS_{DW}$), donde CS_{COR} codifica los consecuentes de la metodología COR, CS_C los parámetros α_i de la conjunción, y CS_{DW} los parámetros β_i de la defuzzificación.

La parte del cromosoma CS_{COR} tiene N genes, cada uno de los cuales representa una etiqueta candidata para los consecuentes de las reglas, siendo los valores posibles que puede tomar entre EP_3 y EG_3 , representado en la implementación con valores enteros.

El algoritmo propuesto realiza una búsqueda aproximada sobre las reglas candidatas con el objetivo de seleccionar el conjunto de consecuentes con mejor cooperación junto con el resto del cromosoma.

La zona del cromosoma dedicada a los parámetros de los operadores, y tiene dos partes:

- Parte de la conjunción, CS_C , con N parámetros α_i (genes) para cada R_i de la BR. Cada gen toma valores en el intervalo $[0,1]$, es decir, entre el mínimo y el producto algebraico.
- Parte de la defuzzificación, CS_{DW} , utilizando N parámetros β_i para cada R_i de la BR. Cada gen toma cualquier valor en el intervalo $[0,10]$.

El AG de tipo CHC [11] es considerado como un modelo evolutivo con un buen balance entre diversidad y convergencia en problemas con grandes espacios de búsqueda.

En cada generación, el algoritmo CHC utiliza una población de padres de tamaño M para generar una población intermedia de M individuos, los cuales son aleatoriamente emparejados y utilizados para generar M descendientes. Se mantiene entonces una competición por la supervivencia, donde los mejores M cromosomas desde las poblaciones de padres y descendientes son seleccionados para constituir la nueva generación.

En la fase de recombinación no se aplica ningún proceso de mutación. En su lugar, cuando la población converge o el proceso de búsqueda deja de progresar adecuadamente (el umbral de cruce llega a 0 y no se generan nuevos descendientes), la población se reinicia. El cromosoma que representa la mejor solución hasta ese momento se utiliza como patrón para generar la nueva población en un cromosoma, mientras que el resto es aleatorio.

Aunque el algoritmo CHC fue concebido para cromosomas con codificación binaria, existen versiones para su uso con cromosomas con codificación real como la empleada en la parte correspondiente a los parámetros de este trabajo, la cual utiliza el $BLX-\alpha$ como operador de cruce ($\alpha=0.5$). El cálculo de la distancia de Hamming se realiza convirtiendo los genes reales en una representación en cadenas y hallando la distancia de Hamming teniendo en cuenta si difiere o no cada uno de los caracteres. Sólo aquellas cadenas con una distancia mayor del umbral son combinados. El umbral se inicializa a $L/4$ siendo L la longitud de la cadena o cromosoma. Cuando ningún descendiente es insertado en la nueva población, el umbral se reduce a 1.

El tamaño de la población es de 50 individuos aleatoriamente inicializados todos salvo uno, con la siguiente configuración:

- Parte de la BR, CS_{COR} , con las N reglas obtenidas mediante el método WM.
- Parte de parámetros de los operadores:
 - Conjunción, CS_C , con los N genes inicializados a 0 para que la t-norma de Dubois sea equivalente a la t-norma del mínimo inicialmente.

- Defuzzificación, CS_{Dw} , con los N genes que representan los pesos de las reglas inicializados a 1, con objeto de partir equivaliendo al ampliamente conocido WECO. A.

La representación y los operadores de cruce elegidos son los siguientes, dependiendo de la parte del cromosoma:

- Parte de la BR, (CS_{COR}): Representado con un vector de enteros. El cruce empleado es estándar en dos puntos.
- Parte de parámetros de los operadores, (CS_C y CS_{Dw}): Representado con un vector de números reales. El cruce utilizado es el descrito anteriormente, BLX- α .

El modelo evolutivo utiliza dos umbrales distintos, uno para la parte del cromosoma con representación entera y otro para la parte con representación real. Ambos se inicializan a $L/4$, siendo L la longitud del vector entero, o la de la cadena en el caso del real. Cuando no se insertan descendientes en la nueva población, los umbrales se reducen en una unidad.

La función objetivo es el clásico Error Cuadrático Medio (ECM), (7).

$$ECM(S)_B = \frac{1}{2} \frac{\sum_{k=1}^P (y_k - S(x_k))^2}{P} \quad (7)$$

donde S es el modelo difuso cuyo Sistema de Inferencia utiliza la t -norma de Dubois como conjunción y la t -norma del mínimo como operador de implicación, y el método de defuzzificación WECO adaptativo con pesos. Esta medida utiliza un conjunto de datos para evaluación constituido por P pares de datos numéricos $Z_k = (x_k, y_k)$, $k=1, \dots, P$, siendo x_k los valores de las variables de entrada y y_k los correspondientes a las variables de salida.

4. ESTUDIO EXPERIMENTAL

En esta Sección se analiza la cooperación entre los diferentes elementos, desarrollando para ello un estudio experimental con una aplicación donde comparamos la precisión de los resultados de los distintos modelos difusos. Para ello, se ha desarrollado un estudio estadístico que incluye el test de ANOVA, Levene y Tamhane [2] con objeto de mostrar la significancia en las mejoras de precisión obtenidas con el modelo cooperativo propuesto. A continuación se describe la aplicación utilizada, y los resultados obtenidos.

4.1. DESCRIPCIÓN DE LA APLICACIÓN

La aplicación utilizada para estudiar el comportamiento práctico del modelo propuesto corresponde a una de las

utilizadas en [8], la cual consiste en un problema de distribución del sistema eléctrico español: el cálculo de costes óptimos teóricos de la línea de media tensión en núcleos urbanos.

Se dispuso de un conjunto de datos de 1059 ciudades que constan de cuatro variables de entrada y una de salida. El dominio de las variables de entrada y salida fue dividido en cinco etiquetas {MP, P, M, G, MG}.

Utilizamos tres tipos de BRs con 65 reglas lingüísticas obtenidas con el método de WM [17], el método COR [5] y el modelo cooperativo presentado. Se obtuvieron desde un conjunto de datos de entrenamiento con el 80% de los datos disponibles, es decir, 847 de las 1059 ciudades, tomados de modo aleatorio. Se ha utilizado validación cruzada de orden 5, es decir, 5 BRs asociadas con 5 conjuntos de entrenamiento. La evaluación de los modelos se realizó con el 20% restante del conjunto inicial, es decir, las 212 ciudades restantes.

4.3 METODOLOGÍA DE COMPARACIÓN

Se han construido varios modelos combinando la BR de WM con los operadores parametrizados, y por otro lado el modelo cooperativo presentado, asimismo también con diferentes tipos de parametrizaciones (conjunción o defuzzificación, o ambas), para comparar su precisión. Dichos modelos son los mostrados en la Tabla 1.

Abrev.	WM BR	COR BR	Conjunc. Adaptat.	Defuzz. Adaptat.
Modelos de Referencia				
WM	•			
COR		•		
Modelos Adaptativos Evolutivos basados en BR de WM				
WM+D _w	•			•
WM+C	•		•	
WM+C+D _w	•		•	•
Modelos Cooperativos Evolutivos propuestos				
D _w -COR				•
C-COR			•	
C-D _w -COR			•	•

Tabla 1. Modelos Difusos del Estudio Experimental

Cada modelo evolutivo se ha ejecutado 30 veces, resultado de la combinación de 6 semillas para el generador de números aleatorios, y sobre 5 conjuntos diferentes de datos, con validación cruzada de orden 5.

Los distintos modelos se han comparado utilizando el ECM (7) que se introdujo en la Sección 3. El ECM considerado es la media aritmética de los 30 resultados. La Tabla 2 muestra las iteraciones realizadas por el modelo evolutivo CHC para cada modelo difuso.

Modelo	Iteraciones
WM+D _w	40.000
WM+C	40.000
WM+C+D _w	60.000
D _w - COR	200.000
C - COR	200.000
C - D _w - COR	300.000

Tabla 2. Evaluaciones realizadas por el algoritmo CHC

4.4 RESULTADOS EXPERIMENTALES Y ANÁLISIS

En esta sección se muestran los resultados y análisis de la experimentación realizada. En primer lugar los correspondientes al ECM de los modelos difusos probados, y en segundo lugar los resultados resumidos del análisis estadístico.

4.4.1 RESULTADOS GENERALES

La Tabla 3 muestra el ECM de los diferentes modelos difusos.

Modelo	ECM _{entrenamiento}	ECM _{prueba}
WM	56135,75	56359,42
COR	50710,82	54584,76
WM+D _w	31443,27	34879,16
WM+C	34371,65	36845,51
WM+C+D _w	23291,91	25016,47
D _w - COR	27077,00	29640,10
C - COR	27239,07	29605,33
C - D _w - COR	17832,85	19855,88

Tabla 3. ECM obtenido con los diferentes modelos.

Analizando la Tabla 3, podemos observar:

- A) En cuanto al modelo con operadores parametrizados, es decir, las tres filas correspondientes a WM+(elemento/s parametrizado/s):
- La parametrización de los operadores es una herramienta para mejorar la precisión del modelo, tal y como se observó en [1 y 10].
 - Los resultados obtenidos con la conjunción y la defuzzificación parametrizadas, mejoran la precisión de los modelos que sólo tienen parametrizada la conjunción o la defuzzificación. Por tanto, existe cooperación entre los parámetros de la conjunción y la defuzzificación para mejorar la precisión.
 - El aprendizaje evolutivo de la conjunción y la defuzzificación a la vez, mejora la precisión obtenida por el método COR sin operadores adaptativos. Por tanto, los operadores adaptativos

son una buena herramienta para el diseño de MDs lingüísticos.

- B) En cuanto al modelo de aprendizaje cooperativo evolutivo, cuyos resultados en la Tabla 3 son los correspondientes a las filas D_w - COR, C - COR y C - D_w - COR:

- Muestran los mejores resultados del estudio experimental.
 - Comparando el ECM obtenido con COR y el del modelo cooperativo completo, la cooperación entre las reglas difusas y los operadores adaptativos es clara.
- C) Globalmente:
- Los mejores resultados se corresponden con los modelos que tienen mayor grado de libertad, es decir, los que utilizan parámetros tanto en la conjunción como en la defuzzificación.

4.4.2 ESTUDIO ESTADÍSTICO

Para comparar los resultados obtenidos con los diferentes modelos, hemos realizado también un análisis estadístico. En primer lugar se realizó el análisis ANOVA de un factor [2] para cada modelo, siendo el factor los modelos utilizados en los test de los conjuntos de datos. Por extensión, no se han incluido las tablas en este trabajo. Dado que se encontraron diferencias significativas para todos los modelos con respecto a los valores medios asociados, se realizó el test de Tamhane [2] con un coeficiente de confianza del 95%, debido a que la hipótesis de igualdad de varianzas ha sido rechazada en los análisis de todos los modelos.

La Tabla 4 resume los resultados obtenidos en el test de Tamhane. Los signos (+) significa que el modelo de la fila seleccionada mejora al modelo de la columna seleccionada, mientras que los signos (-) significan lo contrario. El signo (≈) significa que son similares. Las tablas deben leerse empezando por la fila, por ejemplo: *el modelo D_w - COR (fila 6) mejora al modelo COR (columna 2)*.

Observando la Tabla 4 podemos concluir que:

- Los modelos cooperativos presentan una mejora significativa en cuanto a precisión.
- El modelo cooperativo propuesto (C - D_w - COR), empleando conjunción y defuzzificación, presenta los mejores resultados, mejorando en todos los casos la precisión de los otros modelos.

	WM	COR	WM+D _w	WM+C	WM+C+D _w	D _w -COR	C-COR	C-D _w -COR
WM	r	r	-	r	-	-	-	-
COR	r	r	-	r	-	-	-	-
WM+D _w	+	+	r	-	-	-	-	-
WM+C	r	+	r	r	-	-	-	-
WM+C+D _w	+	+	+	+	r	+	+	-
D _w -COR	+	+	+	+	-	r	r	-
C-COR	+	+	+	+	-	r	r	-
C-D _w -COR	+	+	+	+	+	+	+	r

Tabla 4. Resumen del test estadístico de Tamhane

5. CONCLUSIONES

En este trabajo proponemos un modelo evolutivo cooperativo con el que se consigue aprender un conjunto de reglas que cooperan entre sí junto con los parámetros que ajustan el comportamiento del operador de conjunción y del método de defuzzificación adaptativos.

Los resultados obtenidos muestra la sinergia positiva entre el aprendizaje de reglas y la coadaptación de los parámetros del sistema de inferencia y el método de defuzzificación.

Referencias

- [1] J. Alcalá-Fdez, F. Herrera, F. Márquez, A. Peregrín. Increasing Fuzzy Rules Cooperation Based On Evolutionary Adaptive Inference Systems. *International Journal of Intelligent Systems*, In press, 2006.
- [2] T. W. Anderson. An introduction to multivariate statistical analysis. *John Wiley and Sons*, 1984.
- [3] J. Casillas, O. Cerdón, F. Herrera, L. Magdalena. (Eds.) Interpretability issues in fuzzy modelling, *Springer-Verlag*, 2003.
- [4] J. Casillas, O. Cerdón, F. Herrera, L. Magdalena. (Eds.) Accuracy improvements in linguistic fuzzy modeling, *Springer-Verlag*, 2003.
- [5] J. Casillas, O. Cerdón, F. Herrera. COR: A methodology to improve ad hoc data-driven linguistic rule learning methods by inducing cooperation among rules. *IEEE Transactions on Systems, Man and Cybernetics -Part B: Cybernetics*, Vol. 32, no. 4, Pág. 526-537, 2002.
- [6] J.S. Cho, D.J. Park. Novel fuzzy logic control based on weighting of partially inconsistent rules using neural network. *Journal of Intelligent and*

Fuzzy Systems, Vol. 8, Pág. 99-100, 2000.

- [7] O. Cerdón, F. Herrera, A. Peregrín. Applicability of the Fuzzy Operators in the Design of Fuzzy Logic Controllers. *Fuzzy Sets and Systems*. Vol. 86, Pág. 15-41, 1997.
- [8] O. Cerdón, F. Herrera, A. Peregrín. Characterisation of Implication Operators in Fuzzy Rule Based Systems from Basic Properties. *Proc. of the 9th Congr. sobre Tecnologías y Lógica Fuzzy*, Pág. 163-166, 1999.
- [9] O. Cerdón, F. Herrera, A. Peregrín. Searching for Basic Properties Obtaining Robust Implication Operators in Fuzzy Control. *Fuzzy Sets and Systems*, Vol. 111, Pág. 237-251, 2000.
- [10] O. Cerdón, F. Herrera, F. Márquez, A. Peregrín. A Study on the Evolutionary Adaptive Defuzzification Methods in Fuzzy Modelling. *Internacional Journal of Hybrid Intelligent Systems*, Vol. 1, nº1, Pág. 36-48, 2004.
- [11] L.J. Eshelman. The CHC Adaptive search algorithm: How to have safe search when engaging in Nontraditional genetic recombination. *Foundations of Genetic Algorithms-1*, Rawlins, G.J.E. (Eds), Pág. 265-283, 1991.
- [12] M. Gupta, J. Qi. Theory of T-norms and Fuzzy Inference Methods. *Fuzzy Sets and Systems*, Vol. 40, Pág. 431-450, 1991.
- [13] F. Herrera, F. Márquez, A. Peregrín. Genetic Adaptation of Rule Connectives and Conjunction Operators in Fuzzy Rule Based System: An Experimental Comparative. *Third International Conference of the European Society for Fuzzy Logic and Technology Study*. Pág. 100-104, 2003.
- [14] F. Herrera, F. Márquez, A. Peregrín. Cooperación de Reglas Difusas basada en la Adaptación Evolutiva de los Operadores de Conjunción y los Defuzzificadores. *Coms. del XII Congr. Español sobre Tecnologías y Lógica Fuzzy*. Pág. 231-236, 2004.
- [15] B.D. Liu, C.Y. Chen C-Y., J.Y. Tsao. Design of adaptive fuzzy logic controller based on linguistic-hedge concepts and genetic algorithms. *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 31, nº 1, Pág. 32-53, 2001.
- [16] M. Mizumoto. Pictorial Representations of Fuzzy Connectives, Part I: Cases of T-norms, T-conorms and Averaging Operators. *Fuzzy Sets and Systems*, Vol. 31, Pág. 217-242, 1989.
- [17] L.X. Wang, J.M. Mendel. Generating fuzzy rules by learning from examples. *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 22, nº 6, Pág. 1414-1427, 1992.

Se ana
borros
muestr
tas (i.e
exacta
maxim
un pun
Toda
una me
Se esta
tual de
cepto d
sus pri
Se estu
y la co
aplicaci
Palabr
borroso
schitz, (

1 Introc


Las aplicacio
ral (fuzzifica
en que los ob
y no son dis
Si la vagued
gen (Y) de la
operadores d
asegurar que
sino que las i
deben ser ind
sar mediante
aplicación bo

Aportación al proceso de Descubrimiento de Conocimiento utilizando técnicas de Morfología Matemática	97
Frago Paños, Noé; Fuentes Gonzalez, Ramón	
Análisis de la estabilidad de un sistema borroso en tiempo discreto con LMIS	103
Matías García Rivera, Antonio Barreiro Blas	
Extracción de bases de reglas simples y lingüísticamente interpretables	111
Andrés A. Gersnovier, Iluminada Baturone, Francisco J. Moreno-Velo	
On the solution of fuzzy shortest path problems	117
F. Hernandez, M.T. Lamata y J.L. Verdegay	
Aprendizaje evolutivo cooperativo de reglas y operadores para sistemas difusos lingüísticos	123
F. Herrera; F. A. Márquez; A. Peregrín	
Aplicaciones borrosas maximales y extensionalidad	129
Joan Jacas, Jordi Recasens	
Cálculo de Cantidad de Incertidumbre en Redes de Restricciones Temporales Posibilísticas	135
José M. Juárez, Francisco Guil, Roque Marin	
Análisis Difuso de Redes Neuronales de Clusters Locales	141
C.J. Mantas	
Multi-adjoint concept lattices from a non-commutative perspectiva	147
J. Medina-Moreno, M. Ojeda-Aciego, J. Ruiz-Calviño	
Requerimientos difusos	153
Daniel Montenegro Arenas, Luis Garmendia Salvador, Matilde Santos Peñas	
Control Difuso de la Tasa de Transferencia de Extremo a Extremo en Protocolos de Transporte de Internet	159
Federico Montesino, Diego R. Lopez, Angel Barriga, Santiago Sánchez-Solano	
Reguladores Difusos de Tráfico en Disciplinas de Colas de Routers de Internet	165
Federico Montesino, Angel Barriga, Diego R. Lopez, Santiago Sánchez-Solano	
Comparación de sistemas dinámicos mediante cadenas difusas temporales	171
Juan Moreno-García, Luis Jiménez, José Jesus Castro-Schez	
Selección óptima del nivel de servicio en un sistema de colas fuzzy con fuente de entrada limitada	179
M ^a José Pardo Santiago, David de la Fuente García, Belén Castro Iñigo	
Aplicación del Algoritmo Difuso de C-Medias a la Segmentación de Imágenes de Resonancia Magnética Cerebral	185
Elena Prieto, Marisol Gómez, Josep M ^a Martí, Pablo Lecumberri, Humberto Bustince	
Un nuevo modelo formal de agregación difusa para máquinas vectores soporte multicategoría uno frente a uno	191
J.M. Pucho, J. M. Benítez, J. L. Castro, C. J. Mantas	

Estylf 2006

**XIII Congreso Español sobre
Tecnologías y Lógica Fuzzy**

Organización
Grupo de Investigación ORETO
Escuela Superior de Informática
Universidad de Castilla-La Mancha



ESTYLF 2006
Ciudad Real
20/22 Septiembre