

COOPERACION DE REGLAS DIFUSAS BASADA EN LA ADAPTACION EVOLUTIVA DE LOS OPERADORES DE CONJUNCIÓN Y LOS DEFUZZIFICADORES

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

En este trabajo¹ se estudia el modelado lingüístico adaptativo cuando el operador de conjunción y el defuzzificador son adaptados simultáneamente, es decir, el Sistema de Inferencia y la Interfaz de Defuzzificación al mismo tiempo. Los parámetros de ambos componentes serán aprendidos empleando algoritmos evolutivos. El objetivo de estos modelos es avanzar en el equilibrio entre precisión e interpretabilidad de los Sistemas Difusos.

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

1 INTRODUCCIÓN

Los dos requerimientos generalmente contradictorios en el diseño de Modelos Difusos (MD) son la interpretabilidad y la precisión. 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 la práctica, una de estas dos propiedades prevalece sobre la otra, es decir, los sistemas más interpretables son menos precisos y los más precisos son menos interpretables. Los diseñadores tratan de buscar un balance entre precisión e interpretabilidad, lo que ha producido creciente interés en su estudio [2, 3] y sobre el que versa este trabajo.

El aumento de la precisión de los MD lingüísticos manteniendo el equilibrio con la interpretabilidad se

puede llevar a cabo modificando la forma de las funciones de pertenencia, integrando el diseño de la Base de Conocimiento y el sistema de inferencia, reduciendo la base de reglas, cambiando la estructura del modelo (modificadores lingüísticos, reglas con doble consecuente, bases de conocimiento jerárquicas o con pesos) o parametrizando los componentes del modelo difuso, que es la línea de trabajo en la que se sitúa este estudio.

La parametrización de los MD en la mayoría de los casos se ha realizado introduciendo parámetros en la Interfaz de Defuzzificación [11, 15, 16, 17], y ajustándolos mediante algoritmos evolutivos [9, 18, 19]. Algunos trabajos recurren a la parametrización del Sistema de Inferencia [1, 14, 21], si bien el interés en este procedimiento de adaptación ha sido generalmente inferior entre los autores.

El presente trabajo se ocupa de estudiar el uso de expresiones parametrizadas tanto en el Sistema de Inferencia como en la Interfaz de Defuzzificación simultáneamente, y de su ajuste mediante algoritmos evolutivos. El objetivo de estos modelos es avanzar en el equilibrio entre precisión e interpretabilidad. En [14] se mostró que en el ajuste del Sistema de Inferencia, la mayor influencia corresponde al operador de conjunción frente al de implicación, de modo que en esta ocasión se adapta el Sistema de Inferencia sólo a través del primero.

En la Sección 2 se describen los MD Adaptativos Evolutivos. La Sección 3 desarrolla la experimentación realizada y por último la Sección 4 muestra las conclusiones del estudio.

2 MODELOS DIFUSOS ADAPTATIVOS EVOLUTIVOS

En esta Sección se estudia la parametrización conjunta de los componentes de los MD. Se describirá en primer lugar la correspondiente a la Interfaz de Defuzzificación, seguida del Sistema de Inferencia.

¹ Soportado por el MCyT bajo el Proyecto TIC2002-04036-C05-01

2.1. LA INTERFAZ DE DEFUZZIFICION ADAPTATIVA

La expresión formal (1) se emplea generalmente para generar los métodos de defuzzificación adaptativos,

$$y_0 = \frac{\sum_i^N f(h_i) \times V_i}{\sum_i^N f(h_i)}, \quad (1)$$

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, o bien un parámetro por cada regla de la Base de Conocimiento, w_i , que es la opción utilizada en este trabajo por obtenerse mejores resultados [9]. Por otro lado el término funcional puede ser de tipo producto o potencia, como se muestra en las expresiones (2) y (3).

$$f(h_i) = h_i \times w_i, \quad f(h_i) = h_i^{w_i}. \quad (2), (3)$$

La combinación de estos dos funcionales con el MV o el CG genera cuatro métodos de defuzzificación (D_3 a D_6), expresiones (6) a (9). Los métodos D_1 y D_2 son los métodos clásicos MV y CG ponderados el grado de emparejamiento a los que equivalen los parametrizados cuando el valor de los parámetros es igual a 1 (expresiones (4) y (5)).

D_1 , MV ponderado por h_i : D_2 , CG ponderado por h_i :

$$y_0 = \frac{\sum_i^N h_i \times MV_i}{\sum_i^N h_i}, \quad (4) \quad y_0 = \frac{\sum_i^N h_i \times CG_i}{\sum_i^N h_i}, \quad (5)$$

D_3 , CG Preciso:

$$y_0 = \frac{\sum_i^N h_i^{w_i} \times CG_i}{\sum_i^N h_i^{w_i}}, \quad (6)$$

D_4 :

$$y_0 = \frac{\sum_i^N h_i^{w_i} \times MV_i}{\sum_i^N h_i^{w_i}}, \quad (7)$$

D_5 :

$$y_0 = \frac{\sum_i^N h_i \times w_i \times CG_i}{\sum_i^N h_i \times w_i}, \quad (8)$$

D_6 :

$$y_0 = \frac{\sum_i^N h_i \times w_i \times MV_i}{\sum_i^N h_i \times w_i}. \quad (9)$$

El funcional de tipo producto tiene un efecto equivalente al empleo de reglas con pesos [4], es decir, equivale a un valor que acompaña a cada regla de la Base de Conocimiento y cuyo significado indica qué grado de

importancia debe tener esa regla en el proceso de inferencia. 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

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 [5, 20]. La modificación lingüística de la regla consiste en relajar la estructura de dicha regla cambiando ligeramente el significado de las etiquetas involucradas. Concretamente, la equivalencia se produce cuando la modificación lingüística utiliza la potencia para cambiar la forma de la función de pertenencia del conjunto difuso asociado a la etiqueta lingüística de los antecedentes. La modificación con potencia es una modificación no lineal que mantiene inalterado el soporte del conjunto difuso. Cuando el conjunto difuso es modificado por un valor en la potencia mayor que 1, la función de pertenencia se contrae. Cuando el conjunto difuso se modifica con valores menores que 1, la función de pertenencia se expande.

2.2. EL SISTEMA DE INFERENCIA ADAPTATIVO

La expresión de la Regla Composicional de Inferencia en el modelado difuso con fuzzificación puntual es mostrada en la expresión (10),

$$B'(y) = I(C(A_1(x_1), \dots, A_n(x_n)), B(y)), \quad (10)$$

donde B' es la función de pertenencia del consecuente inferido, I es el operador de implicación, C el operador de conjunción, 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 B el consecuente de la regla.

El sistema de inferencia pues, emplea dos operadores: el de conjunción, $C(\cdot)$ para calcular el grado de emparejamiento, y el de implicación, $I(\cdot)$, lo cual podría expresarse formalmente en (11) para el caso de n variables de entrada y un consecuente.

$$I(C(x_1, \dots, x_n), y) \quad (11)$$

Con objeto de obtener un Sistema de Inferencia adaptativo, las alternativas que se presentan consisten en emplear para cualquiera de los dos operadores, una selección que tenga parámetros en su expresión, donde w y w' son los parámetros de I y C respectivamente, tal y como muestran (12) y (13). Trabajos previos [14] demostraron la mayor ganancia de precisión cuando se emplea un w ó w' para cada regla de la Base de Conocimiento, por lo que aquí sólo se empleará así.

$$I_w(C(x_1, \dots, x_n), y) \quad (12)$$

$$I(C_w(x_1, \dots, x_n), y) \quad (13)$$

El aprendizaje de dichos parámetros puede llevarse a cabo mediante algoritmos evolutivos. Este proceso puede ser considerado como una alternativa o complemento a otros métodos que proporcionan precisión [8]. El efecto obtenido empleando un parámetro individual para cada regla es el de adaptar localmente la inferencia para cada regla de la Base de Conocimiento.

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 [7]. En este trabajo utilizaremos la t-norma del mínimo y tres t-normas parametrizadas recogidas en [13] cuyas expresiones son (14), (15) y (16).

$$\text{Frank } T_{\text{Frank}}(x, y) = \log \left(1 + \frac{(x-1)(y-1)}{1} \right) \quad (14)$$

$$\text{Dombi } T_{\text{Dombi}}(x, y) = \frac{1}{1 + \sqrt{\frac{1-x}{x} + \frac{1-y}{y}}} \quad (15)$$

$$\text{Dubois } T_{\text{Dubois}}(x, y) = \frac{x \wedge y}{\text{Max}(x, y)} \quad (16)$$

En [14] 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 cuando los conjuntos difusos son simétricos y se emplean métodos de defuzzificación basados en CG y MV (los más frecuentes). Por este motivo, en este trabajo se utiliza la parametrización del Sistema de Inferencia exclusivamente mediante el operador de conjunción.

Los operadores de conjunción adaptativos modulan la influencia del grado de emparejamiento atenuándolo o acentuándolo. Este cambio no es lineal debido a que las expresiones de las t-normas usadas no lo son. Su efecto se asemeja a un conocido mecanismo para modificar el significado lingüístico de la estructura de las reglas [5, 20] que consiste en relajar la estructura de la regla cambiando el significado de las etiquetas involucradas. Por tanto, un operador de conjunción adaptativo actúa similarmente a un modificador de las funciones de pertenencia asociadas a los antecedentes de las reglas. Las t-normas parametrizadas como operadores de conjunción sólo producen efectos de concentración.

2.3. CONJUNCIÓN Y DEFUZZIFICACIÓN ADAPTATIVAS

En esta sección se estudia la construcción de MD con el Sistema de Inferencia y la Interfaz de Defuzzificación adaptativos. Para ello se van a emplear los componentes parametrizados descritos en las secciones 2.1 y 2.2, y se va a estudiar el efecto conjunto que producen.

La Tabla 1 resume el efecto que se consigue tanto con la Inferencia como con la Interfaz de Defuzzificación Adaptativas descritas en las secciones anteriores.

Tabla 1: Efectos del uso de los operadores adaptativos

	Inferencia Adaptativa (Conjunción)	Defuzzificación Adaptativa	
		Potencia	Producto
Añade Pesos o Niveles de Confianza			X
Modificación Lingüística Concentra Antecedentes	X	X	
Modificación Lingüística Dilata Antecedentes		X	

Resumiendo, las combinaciones de Inferencia Adaptativa con el operador de conjunción parametrizado y el Interfaz de Defuzzificación Adaptativo basado en un método que trabaja en Modo B – FITA con funcional de tipo:

Producto: introduce un peso para cada regla, y permite modificar los antecedentes de las reglas ajustando un grado de concentración de los mismos.

Potencia: permite modificar lingüísticamente el significado de las funciones de pertenencia de la regla tanto dilatando como concentrando los antecedentes.

En ambos casos la adaptación de los parámetros del sistema resultará en el conjunto de reglas de la Base de Conocimiento que mejor cooperan para producir el mejor comportamiento del sistema difuso.

3. ESTUDIO EXPERIMENTAL

En esta Sección se ha planteado una experimentación que tiene como objetivo observar el comportamiento de los MD adaptativos basados en el empleo de operadores parametrizados tanto en el Sistema de Inferencia como en la Interfaz de Defuzzificación según se describió en la sección previa. Para ello, se construirán varios MD y se comprobará su comportamiento en un problema práctico.

3.1. DESCRIPCIÓN DE LA APLICACIÓN

La aplicación utilizada para estudiar el comportamiento práctico de los diferentes MD corresponde a una de las utilizadas en [6], la cual consiste en un problema de distribución del sistema eléctrico español: Se trata del 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}.

Las bases de reglas, de 65 reglas de tipo Mamdani, se generaron mediante el Método de Wang y Mendel [22] con los datos de entrenamiento, que son el 80% de los datos disponibles, es decir, 847 de las 1059 ciudades,

tomados de modo aleatorio. La evaluación de los modelos se realizó con el 20% restante del conjunto inicial, es decir, las 212 ciudades restantes.

3.2. EL ALGORITMO EVOLUTIVO CHC

Se ha empleado el algoritmo evolutivo CHC [10], el cual es considerado como un modelo evolutivo con un buen balance entre diversidad y convergencia en problemas con grandes espacios de búsqueda.

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 este trabajo, la cual utiliza el BLX- como operador de cruce. 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.

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 este caso se ha ejecutado con 40000 evaluaciones. La población empleada fue de 50 (inicializados aleatoriamente con excepción del primer cromosoma que fue inicializado a 0 para el caso de la t-norma de Dubois (equivale a la t-norma clásica del mínimo), a 1 en caso de la de Dombi (equivale a la t-norma de Hamacher) y a 0.5 en caso de la de Frank, y a 1 para los métodos de defuzzificación). El valor en el operador de cruce es 0,5. El intervalo de búsqueda fue establecido en el rango $[0,1]$ para la t-norma de Dubois, $(0,10]$ para la de Dombi, y $(0,100]$ para la de Frank. En el caso de los métodos de defuzzificación adaptativos el intervalo es $[0,10]$.

3.3 METODOLOGÍA DE COMPARACIÓN

Se han construido varios modelos combinando el Sistema de Inferencia Adaptativo junto con la Interfaz de Defuzzificación Adaptativa. Como operador de conjunción se han empleado las tres t-normas parametrizadas citadas en la Sección 2.2, manteniendo siempre como operador de implicación la t-norma del mínimo. En cuanto a la Interfaz de Defuzzificación, con objeto de reducir la extensión del trabajo, se han empleado los métodos adaptativos D_3 y D_5 (ambos basados en CG). Como modelos no adaptativos de referencia se ha tomado la t-norma del mínimo para

modelar tanto el operador de conjunción como el de implicación y el método de defuzzificación elegido es D_2 .

La medida de comparación de los resultados de los modelos elegida es el Error Cuadrático Medio (ECM(.)),

$$ECM(S[i,j]) = \frac{1}{2} \frac{\sum_{k=1}^P (y_k - S[i,j](x_k))^2}{N} \quad (17)$$

donde $S[i,j]$ es el modelo difuso en el que el Sistema de Inferencia se construye utilizando el operador de conjunción C_i y la Interfaz de Defuzzificación que emplea el método de defuzzificación D_j . Esta medida precisa del empleo de un conjunto de datos de 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 sus salidas asociadas.

En realidad el ECM(.) empleado es la media aritmética de los ECM(.) obtenidos realizando 30 procesos de evolución con cada modelo: 6 semillas diferentes para el generador de números aleatorios del algoritmo evolutivo por 5 particiones de datos con validación cruzada de orden 5.

Con objeto de mostrar con claridad el incremento en la precisión de los modelos adaptativos, se ha empleado el porcentaje de mejora $PM(.)$ (18) presentado por el ECM,

$$PM(i,j) = 100 \left(1 - \frac{ECM(S(i,j))}{ECM(S_{NA}(i))} \right) \quad (18)$$

donde $S_{NA}(.)$ es el modelo de referencia no adaptativo con el operador de conjunción C_i con sus parámetros inicializados al valor comentado con anterioridad.

3.4 RESULTADOS EXPERIMENTALES Y ANÁLISIS

En esta sección se muestran los resultados y análisis de la experimentación realizada. En primer lugar se muestran los resultados obtenidos para la conjunción y la defuzzificación adaptativas, y posteriormente, los de utilizar esta técnica combinada con una técnica muy conocida para aumentar la precisión de los MD lingüísticos: el ajuste de las funciones de pertenencia.

3.4.1 CONJUNCIÓN Y DEFUZZIFICACIÓN ADAPTATIVAS

Las siguientes tablas muestran los resultados de la experimentación:

Tabla 2: Errores cuadráticos medios de los modelos iniciales con los parámetros inicializados a los valores descritos en la Sección 3.3.

Tabla 3: Errores cuadráticos medios obtenidos por los modelos evolucionados.

Tabla 4: Porcentajes de mejora tras el proceso evolutivo, es decir, de la Tabla 3 respecto de la 2.

Tabla 2: Error Cuadrático Medio inicial

ECM inicial	Entrenamiento	Prueba
Dubois	56135,74	56359,42
Dombi	55418,16	55531,72
Frank	80441,20	80597,13

Tabla 3: Error Cuadrático Medio obtenido

ECM	Entrenamiento		Prueba	
	D ₃	D ₅	D ₃	D ₅
Dubois	21757,02	21985,91	25545,22	24974,17
Dombi	22334,75	25915,42	25264,46	29228,98
Frank	28673,98	23145,21	33535,45	26887,47

Tabla 4: Porcentaje de Mejora de los modelos adaptativos

PM	Entrenamiento		Prueba	
	D ₃	D ₅	D ₃	D ₅
Dubois	61,24	60,83	54,68	55,69
Dombi	59,70	53,24	54,51	47,38
Frank	64,35	71,23	58,39	66,64

Analizando las tablas 3 y 4, los modelos que utilizan el sistema de inferencia y la interfaz de defuzzificación adaptativos mejoran en todos los casos, tanto en entrenamiento como en prueba la precisión con respecto al modelo de partida no adaptativo. Los mejores resultados corresponden al caso de la t-norma parametrizada de Dubois, seguramente debido al menor espacio de búsqueda que se precisa utilizar para ella.

Los porcentajes de mejora que se observan en la Tabla 4 muestran un importante progreso en los modelos adaptativos, siendo los mejores aquellos que inicialmente presentaba mayores errores: t-norma de Frank.

En relación al método de defuzzificación, en el caso de la t-norma de Dubois no se aprecia diferencia entre el empleo del basado en funcional potencia (D₃) y producto (D₅). Sin embargo, el Sistema de Inferencia Adaptativo basado en Dombi obtiene las mejores cifras con D₃ mientras que el de Frank lo hace con D₅.

Es posible afirmar que la t-norma de Dubois se ha mostrado como la más adecuada ya que es la más sencilla computacionalmente, el intervalo de búsqueda que debe emplear el algoritmo evolutivo es el más pequeño, y obtiene los mejores resultados independientemente de emplearla combinada con un método de defuzzificación adaptativo basado en funcional producto o potencia.

3.4.2 COMBINACIÓN DE LA CONJUNCIÓN Y DEFUZZIFICACIÓN ADAPTATIVAS CON EL AJUSTE DE LAS FUNCIONES DE PERTENENCIA

En esta sección se presentan los resultados de combinar la técnica de la conjunción y defuzzificación adaptativas estudiada en este trabajo, con el empleo de una de las técnicas más conocidas y que ofrecen mejores resultados para mejorar la precisión de los MD lingüísticos: la

adaptación de las funciones de pertenencia de los conjuntos difusos de las particiones de las variables implicadas, contenidas en la base de datos.

Para combinar ambas técnicas, el cromosoma del algoritmo evolutivo CHC ha sido ampliado con los genes correspondientes a la descripción de los conjuntos difusos de las particiones de las variables, de modo que la evolución de la base de datos y los parámetros del sistema se ha realizado conjuntamente. El número de evaluaciones empleadas en el algoritmo evolutivo también se ha elevado hasta 60000.

Las siguientes tablas muestran los resultados obtenidos en la experimentación:

Tabla 5: Errores cuadráticos medios obtenidos adaptando sólo las funciones de pertenencia. Para ello, el parámetro de las t-normas se ha fijado a los valores de inicialización descritos en la Sección 3.3. El algoritmo CHC ha empleado 30000 evaluaciones, y se inicializó un cromosoma con los valores correspondientes a la base de datos inicial, y el resto de modo aleatorio.

Tabla 6: Errores cuadráticos medios obtenidos por los modelos evolutivos conjuntos.

Tabla 7: Porcentajes de mejora del modelo evolutivo conjunto: mejora de la Tabla 6 respecto de la Tabla 2.

Tabla 5: Error Cuadrático medio obtenido empleando sólo la adaptación de las funciones de pertenencia

	Entrenamiento	Prueba
Dubois	14320,62	17460,91
Dombi	14004,49	17933,84
Frank	15304,25	17921,22

Tabla 6: Error Cuadrático Medio adaptando al mismo tiempo conjunción, defuzz. y funciones de pertenencia

ECM	Entrenamiento		Prueba	
	D ₃	D ₅	D ₃	D ₅
Dubois	7927,37	6149,11	11367,18	9580,60
Dombi	7060,52	7247,97	10156,85	10497,60
Frank	8001,53	7292,56	11255,34	10405,02

Tabla 7: Porcentajes de Mejora del modelo adap. conjunto

PM	Entrenamiento		Prueba	
	D ₃	D ₅	D ₃	D ₅
Dubois	85,88	89,05	79,83	83,00
Dombi	87,26	86,92	81,71	81,10
Frank	90,05	90,93	86,04	87,09

Observando la Tabla 5, y en comparación con la Tabla 3, se aprecia que la tradicional adaptación de las funciones de pertenencia es un método que aporta mayor incremento en la precisión que la adaptación de los operadores. Sin embargo, la combinación de ambas técnicas, Tabla 6, ofrece unos resultados notablemente mejores aún, siendo el error cuadrático medio en entrenamiento

aproximadamente la mitad que empleando sólo la adaptación de las funciones de pertenencia. Los porcentajes de mejora, Tabla 7, con respecto a la base de conocimiento original obtenida por el método de Wang y Mendel son de un orden de magnitud muy importante.

Analizando estos resultados podemos afirmar que la adaptación de los operadores de conjunción y defuzzificación no es un método que compita en precisión con otros métodos sino que se trata de un complemento que puede aportar mejoras finales muy importantes.

4. CONCLUSIONES

En el ámbito del compromiso entre precisión e interpretabilidad de los sistemas difusos lingüísticos, este trabajo trata sobre el empleo de modelos difusos con dos de sus componentes parametrizadas: el Sistema de Inferencia y la Interfaz de Defuzzificación, empleando inferencia y defuzzificación locales, es decir, sendos parámetros para cada regla.

El resultado se ha mostrado como beneficioso, concluyéndose pues que este método constituye una alternativa que mejora a otras similares que sólo parametrizaban una componente. Estas ventajas no compiten con otros métodos tradicionales como la adaptación de las funciones de pertenencia sino que se complementan como se ha mostrado en la experimentación llevada a cabo.

Referencias

- [1] I. Batyrshin, O. Kaynak. Fuzzy Modeling Based on Generalized Conjunction Operators. *IEEE Transaction on Fuzzy Systems*, Vol. 10, nº 5, Págs 678-683, 2003.
- [2] J. Casillas, O. Cordón, F. Herrera, L. Magdalena. (Eds.) Interpretability issues in fuzzy modelling, *Springer-Verlag*. 2003.
- [3] J. Casillas, O. Cordón, F. Herrera, L. Magdalena (Eds.) Accuracy improvements in linguistic fuzzy modeling, *Springer-Verlag*. 2003
- [4] 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.
- [5] O. Cordón, M.J. del Jesus, F. Herrera. Genetic learning of fuzzy rule-based classification systems cooperating with fuzzy reasoning methods. *International Journal of Intelligent Systems*, Vol. 13, Pág. 1025-1053, 1998.
- [6] O. Cordón, 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.
- [7] O. Cordón, 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.
- [8] O. Cordón, F. Herrera, F. Hoffmann, L. Magdalena. Genetic Fuzzy Systems: evolutionary tuning and learning of knowledge bases, *World Scientific*. 2001.
- [9] O. Cordón, F. Herrera, F. Márquez, A. Peregrín. A Study on the Evolutionary Adaptive Defuzzification Methods in Fuzzy Modelling. *International Journal of Hybrid Intelligent Systems*, Vol.1,nº1, Pág. 36-48, 2004.
- [10] 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.
- [11] A.O. Esogbue, Q. Song, W.E. Hearnese II. Defuzzification filters and applications to power system stabilization problems. *Journal of Mathematical Analysis and Applications*, Vol.251, Pág. 406-432, 2000
- [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, M. Lozano J.L. Verdegay. Dynamic and Heuristic Fuzzy Connectives-Based Crossover Operators for Controlling the Diversity and Convergence of Real-Coded Genetic Algorithms. *International Journal of Intelligent Systems*, Vol. 11, Pág. 1013-1040, 1996.
- [14] 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.
- [15] T. Jiang, Y. Li. Generalized defuzzification strategies and their parameter learning procedures. *IEEE Transactions on Fuzzy Systems*, Vol. 4, nº 1, Pág. 64-71, 1996.
- [16] A. Kandel, M. Friedman. Defuzzification using most typical values. *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 28, nº 6, Pág. 901-906, 1998.
- [17] H. Kiendl, Non - translation - invariant defuzzification. *Proceedings of the 6th FUZZ-IEEE'97*, Pág. 737-741, 1997.
- [18] D. Kim. An Accurate COG Defuzzifier Design by the Co-adaptation of Learning and Evolution, *Proc. 9th IEEE International Conf. on Fuzzy Systems*, Pág. 741-747, 2000.
- [19] D. Kim, Y. Choi, S. Lee. An accurate COG defuzzifier design using Lamarckian coadaptation of learning and evolution. *Fuzzy Sets and Systems*, Vol. 130, nº 2, Pág. 207-225, 2002.
- [20] B.D. Liu, C.Y. Chen C-Y., J.Y. Tsao. Design of adaptative 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.
- [21] T. Whalen. Parametrized R-implications. *Fuzzy Sets and Systems*, Vol. 134, Pág. 231-281, 2003.
- [22] 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.