

# GENERACIÓN AUTOMÁTICA DE CONTROLADORES BORROSO INTERPRETABLES PARA REGULACIÓN DE PROFUNDIDAD DE VEHÍCULO SUBACUÁTICO OPERADO REMOTAMENTE ROV

Fredman Jiménez Cifuentes<sup>1</sup>, Héctor Gonzáles León<sup>2</sup>, Juan Contreras Montes<sup>3</sup>,

## Resumen:

En este artículo se presenta un novedoso método para la generación automática de controladores a partir de datos experimentales de entrada y salida del proceso de inmersión de un ROV. El controlador borroso generado presenta una partición de las variables de entrada (antecedentes) mediante conjuntos triangulares con interpolación de 0.5 y consecuentes tipo singleton. La evaluación de los antecedentes de las reglas es realizada por un operador del tipo promedio ponderado en vez de una t-norma. Se presenta una aplicación en un sistema de inmersión de un vehículo subacuático operado remotamente ROV en la que el sistema es entrenado con los datos generados por la acción de un operador humano. El controlador borroso generado tiene capacidad de adaptación ante cambio de la dinámica del ROV o del medio donde se sumerge.

Palabras Clave: controlador borroso, Control de profundidad, ROV

## 1. INTRODUCCIÓN

Los vehículos subacuáticos no tripulados son considerados una valiosa herramienta para las operaciones subacuáticas científicas y/o militares, razón por la cual ha existido un auge en la investigación en este campo durante la última década [9]. Uno de los tópicos más estudiados es se relaciona con el control de inmersión o profundidad debido a la dinámica combinada no lineal del medio marino y del vehículo mismo [1], [9], [10], [15], [16]. Debido a la dinámica

---

<sup>1</sup> Estudiante de Ingeniería Naval Especialidad Electrónica, Escuela Naval Almirante Padilla, Cartagena, Colombia, [fredmanj@hotmail.com](mailto:fredmanj@hotmail.com)

<sup>2</sup> Estudiante de Ingeniería Naval Especialidad Electrónica, Escuela Naval Almirante Padilla, Cartagena, Colombia, [hecgonzalez54@hotmail.com](mailto:hecgonzalez54@hotmail.com)

<sup>3</sup> Doctor en Ciencias Técnicas, Docente Investigador Escuela Naval Almirante Padilla, Cartagena, Colombia, [epcontrerasj@ieee.org](mailto:epcontrerasj@ieee.org)

Apoyos y Subvenciones: Escuela Naval Almirante Padilla – Facultad de Ingeniería Naval

no lineal, los investigadores han tenido que recurrir a técnicas basadas en inteligencia artificial, siendo la lógica difusa una de las que mejores resultados ha arrojado.

Los sistemas de inferencia difusos, o borrosos, han demostrado un gran potencial para presentar la dinámica de un sistema mediante reglas difusas del tipo SI-ENTONCES (IF-THEN), siendo su mayor atractivo su capacidad para describir los sistemas reales de manera similar a como lo interpreta un operador humano. Inicialmente, un sistema difuso era construido a partir de la información suministrada por un experto. Sin embargo, muy pronto apareció el problema de que para sistemas complejos y parcialmente desconocidos el modelo difuso así construido no alcanzaba resultados satisfactorios [10]. Por esta razón, en los últimos años se percibe un creciente auge de los investigadores en el desarrollo de métodos automáticos para construir un sistema difuso a partir de datos experimentales de entrada y salida [1]-[17],[19]-[24].

Una de las primeras propuestas para diseño automático de sistemas difusos a partir de los datos es la denominada table look-up écheme propuesta por Wang [24]. En 1993, Sugeno y Yasukawa [23] propusieron una metodología para identificación de parámetros de modelos difusos empleando consecuentes tipo singletons, pero requiere de muchas reglas y presenta una pobre capacidad de descripción. Otros métodos importantes emplean el gradiente descendente, técnicas de agrupamiento o clustering y algoritmos evolutivos. Con excepción del último método todos requieren de un diseño previo de las funciones de pertenencia.

La técnica más adecuada para la obtención de modelos borrosos han sido los algoritmos de agrupamiento borroso, siendo los métodos de Fuzzy C-Means y de Gustafson-Kessel [12] los más empleados. Se han realizado diversas variaciones a estos algoritmos de agrupamiento. Nauck y Kruse [17],[18] proponen técnicas de agrupamiento neuro-difusas; Espinosa y Vandewalle [7],[8] presentan una metodología para extraer reglas a partir de los datos en un marco de integridad lingüística incluyendo algoritmos de fusión para agrupar conjuntos cuyos valores modales estén a una distancia muy cercana. Sala [21],[22] introduce una novedosa técnica basada en el error de inferencia para aproximar funciones empleando partición suma 1 con conjuntos triangulares; Diez et al [5] proponen variaciones a los algoritmos de agrupamiento para mejorar la interpretabilidad y descubrir estructuras afines locales en los


modelos borrosos obtenidos. Paiva y Dourado [19] presentan un modelo generado por medio del entrenamiento de una red neuro-difusa implementado en dos fases: en la primera fase, se obtiene la estructura del modelo empleando un algoritmo clustering substractivo, lo cual permite extraer las reglas a partir de datos de entrada y salida; en la segunda fase, se realiza la sintonización de los parámetros del modelo mediante una red neuronal que emplea backpropagation. Guillaume y Charnomordic [11] proponen una estrategia para generar particiones difusas interpretables a partir de los datos mediante una metodología, que denominan partición jerárquica difusa (HFP), en la que en vez de incorporar datos en cada iteración agrega conjuntos difusos. También presentan un algoritmo de fusión de los conjuntos difusos basado en métricas adecuadas que garanticen la interpretabilidad semántica. Joo y Lee [13],[14] proponen un aproximador universal para cualquier función continua en un conjunto compacto empleando un sistema difuso jerárquico en el que las salidas de las capas previas no son usadas en las partes IF de la reglas difusas sino en las partes THEN. Chen y Saif [2] proponen un sistema difuso novedoso que emplea bases de reglas dinámicas, lo que implica que las reglas pueden cambiar con las entradas y facilita su empleo tanto para modelación como para control.

El afán de generar, a partir de datos, sistemas difusos que aproximen la dinámica de un sistema con alta precisión ha conllevado a otro problema: la pérdida de interpretabilidad del sistema difuso generado. Hay tres criterios básicos que definen la interpretabilidad (Espinosa y Vandewalle [7], Paiva y Dourado [19] ) de un modelo borroso:


- 1) Distinguible: cada etiqueta lingüística debe tener significado semántico y cada conjunto borroso debe tener un rango definido en el universo de discurso. Las funciones de pertenencia deben ser claramente diferentes.
- 2) El número de funciones de pertenencia: no debe exceder de 9 términos distintos
- 3) Número de reglas: debe ser limitado, aunque en este punto no existe consenso sobre un número máximo de reglas.

La figura 1 muestra dos casos que suelen presentarse luego del proceso de entrenamiento para obtener un modelo difuso a partir de datos de entrada y salida. En la figura 1(a), un valor puede tener una pertenencia alta en el conjunto NEGATIVO y al mismo tiempo una

pertenencia alta en el conjunto POSITIVO, indicando que es bastante negativo y al mismo tiempo bastante positivo, lo que resulta incomprensible para un ser humano; en la figura 1(b), se muestra una partición con 5 conjuntos: MUY PEQUEÑO, MP, PEQUEÑO, P, MEDIANO, M, GRANDE, G, y MUY GRANDE, MG. En este caso, un elemento puede tener pertenencia en todos los conjuntos; por ejemplo, el valor 4 puede considerarse muy pequeño, pequeño, mediano, grande y muy grande a la vez, lo cual resulta simplemente absurdo.



1(a)



1(b)

Figura 1. Particiones que violan la interpretabilidad

## 2. ERROR DE INFERENCIA

En lógica borrosa es común tratar con reglas del tipo “Si  $u$  es  $A$ , entonces  $y$  es  $B$ ”, donde  $u$  y  $y$  representan dos variables numéricas, y  $A$  y  $B$  son dos conjuntos borrosos de entrada y salida respectivamente, definidos en los universos  $U$  y  $Y$ . La regla mencionada es equivalente a la inecuación

$$u_A(u) \leq u_B(y) \quad (1)$$

El error de inferencia  $\varepsilon$ , concebido como la distancia conceptual al conjunto conclusión de la regla, está definido por Sala (1998) como

$$\varepsilon \approx \begin{cases} 0 & \dots u_A(u) \leq u_B(y) \\ u_A(u) - u_B(y) & \dots u_A(u) > u_B(y) \end{cases} \quad (2)$$

El método propuesto para crear un sistema borroso basado en reglas que se aproxime a una función de una entrada una salida, con un error de inferencia nulo, debe cumplir con la condición

$$u_A(u) = u_B(y) \quad (3)$$

lo cual minimiza el error de inferencia del modelo borroso obtenido. En el caso de una regla del tipo “Si u es A, entonces y es B”. Si el sistema tiene n entrada se debe representar por una regla del tipo “Si u1 es A1 , u2 es A2 , ..., um es Am, entonces y es B”, por lo cual el sistema generado deberá cumplir con la condición

$$((u_{A_1}(x_k) \wedge u_{A_2}(x_k) \wedge \dots \wedge u_{A_m}(x_k)) = u_B(y_k) \quad (4)$$

donde  $\wedge$  representa un operador de conjunción o de combinación de la lógica borrosa.

Si se emplean consecuentes tipo singleton, solo se consideran los valores modales de las funciones de pertenencia del antecedente, considerando que la ubicación del valor modal de la función de pertenencia triangular en el consecuente se puede asimilar a un singleton.

### 3. IDENTIFICACIÓN BORROSA

#### 3.1 Estructura del Modelo Borroso

Buscando un equilibrio entre la aproximación numérica y la interpretabilidad del sistema borroso resultante se consideran los siguientes criterios para la selección de los parámetros

### Funciones de Pertenencia

La partición de los universos de las variables de entrada en el proceso de aprendizaje se hace con conjuntos triangulares normalizados con solapamiento específico de 0.5. Las funciones de pertenencia triangulares permiten la reconstrucción del valor lingüístico en el mismo valor numérico, luego de aplicar un método de defuzzyficación [20]; además, el solapamiento en 0.5 asegura que los soportes de los conjuntos difusos sean diferentes.

Los conjuntos difusos generados para la variable de salida son tipo singleton.

### Distribución de las Funciones de Pertenencia

Los conjuntos difusos triangulares de las variables de entrada se distribuyen uniformemente en cada universo respectivo de manera tal que cada uno de los elementos de los universos de discurso de cada variable debe pertenecer, al menos, a un conjunto difuso.

### Operadores

Para la combinación de los antecedentes se emplea un operador de combinación tipo OWA, como se muestra en (6)

### Método de Inferencia

El método de inferencia empleado está dado por

$$f(x^{(i)}) = \frac{\sum_{j=1}^L \delta_j m_j(x^{(i)})}{\sum_{j=1}^L m_j(x^{(i)})} \quad (5)$$

donde

$$m_j(x^{(i)}) = u_{A_1^j}(x_1^{(i)}) \cdot u_{A_2^j}(x_2^{(i)}) \cdot \dots \cdot u_{A_n^j}(x_n^{(i)}) = \frac{u_{A_1^j}(x_1^{(i)}) + u_{A_2^j}(x_2^{(i)}) + \dots + u_{A_n^j}(x_n^{(i)})}{n} \quad (6)$$

es el grado de la salida de la  $j$ -ésima regla con  $n$  antecedentes,  $\delta_j$  es el valor del singleton correspondiente a la regla  $j$ .

### 3.2 Algoritmo De Identificación Borrosa

El algoritmo para generación de sistemas difusos interpretables a partir de los datos se basa en la minimización del error de inferencia. Solo requiere la definición previa de la forma de las funciones de pertenencia que conformarán la partición del antecedente y calcula el número y la distribución final de las funciones de pertenencia del antecedente, garantizando partición suma 1, así como las posiciones de los consecuentes, del tipo singleton.

Dado una colección de datos experimentales de entrada y salida  $\{x_k, y_k\}$ ,  $k=1, \dots, N$ , donde  $x_k$  es el vector de entrada  $p$ -dimensional  $x_k^1, x_k^2, \dots, x_k^p$  y  $y_k$  es el vector unidimensional de salida

- Organización del conjunto de  $N$  pares de datos de entrada – salida  $\{(x_i, y_i) \mid i=1,2,\dots,N\}$ , donde  $x_i \in \mathfrak{R}^p$  son vectores de entrada y  $y_i$  son escalares de salida.
- Determinación de los rangos de los universos de cada variable de acuerdo a los valores máximos y mínimos de los datos asociados  $[x_i^-, x_i^+]$ ,  $[y^-, y^+]$ .
- Distribución de las funciones de pertenencia triangulares sobre cada universo. Se tiene como condición general que el vértice con valor de pertenencia uno (valor modal) cae en el centro de la región cubierta por la función de pertenencia mientras que los otros dos vértices, con valor de pertenencia iguales a cero, caen en los centros de las dos regiones vecinas. Para poder aproximar eficientemente los extremos inferior y superior de una función representada por los datos es necesario que en la partición triangular las funciones de pertenencia que cubren el inicio y final del universo coincidan sus vértices con valor de pertenencia uno con sus vértices izquierdo y derecho respectivamente, como se aprecia en la figura 2.




Fig. 2. Partición triangular suma 1

- Cálculo de la posición de los valores modales de la(s) variable(s) de entrada, de acuerdo a

$$\begin{aligned}
& \text{if } u_{A_k^{(n)}}(x_k^{(i)}) = 1 \\
& \quad y_{s_k^{(n)}} = y[i] \\
& \text{end}
\end{aligned} \tag{7}$$

donde  $y_{s_k^{(n)}}$  corresponde a la proyección sobre el espacio de salida de la evaluación del dato  $x^{(i)}$  de la  $k$ -ésima variable de entrada en el  $n$ -ésimo conjunto de la partición correspondiente. El valor de la salida correspondiente a dicha proyección está dado por el valor de la  $i$ -ésima posición del vector de salida  $y$ . De esta manera se aplica el criterio de error de inferencia nulo empleando consecuentes tipo singleton.

- e) Determinación de las reglas. El número máximo de reglas está determinado por el número de conjuntos de cada variable de entrada multiplicado por el número de variables; es decir igual a  $n \times k$ . Cuando existen singletons ubicados en la misma posición, se combinan los antecedentes de acuerdo a (3) en una sola regla, lo que permite reducir el número de reglas.
- f) Validación del modelo empleando el método de inferencia descrito por (5), donde  $\delta_j$  es el valor del singleton correspondiente a la regla  $j$ .
- g) Ajuste de los parámetros, reubicando los singletons de salida, empleando el método de mínimos cuadrados. La ecuación (5) puede expresarse de la forma

$$f(x^{(i)}) = \sum_{j=1}^L \delta_j \cdot w_j(x^{(i)}) \tag{8}$$

donde

$$w_j(x^{(i)}) = \frac{m_j(x^{(i)})}{\sum_{j=1}^L m_j(x^{(i)})} = w_j^i \tag{9}$$

Los valores de salida pueden representarse como  $Y = W\theta + E$ , que en forma matricial está dada por

$$\begin{bmatrix} y^1 \\ y^2 \\ \vdots \\ y^L \end{bmatrix}_Y = \begin{bmatrix} w_1^1 & w_2^1 & \dots & w_L^1 \\ w_1^2 & w_2^2 & \dots & w_L^2 \\ \vdots & \vdots & \ddots & \vdots \\ w_1^n & w_2^n & \dots & w_L^n \end{bmatrix}_W \begin{bmatrix} y^{-1} \\ y^{-2} \\ \vdots \\ y^{-L} \end{bmatrix}_\theta + \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix}_E \quad (10)$$

donde E es el error de aproximación, el cual debe ser minimizado. Empleando la norma del error cuadrático se tiene

$$E^2 = (Y - W\theta)^2 = (Y^2 - 2YW\theta + (W\theta)^2) \quad (11)$$

La solución a este problema de mínimos cuadrados está dada por

$$\frac{\partial E^2}{\partial \theta} = 0 = -2YW + 2W^T W \theta \quad (12)$$

de donde se obtiene

$$\theta = \frac{Y^T W}{W^T W} = (W^T W)^{-1} Y^T W \quad (13)$$

Esta solución es válida si  $(W^T W)$  es no singular; en caso contrario la estimación por mínimos cuadrados debe hacerse de manera recursiva.

- h) Terminar si la medida del error cuadrático medio MSE es menor a una medida previamente establecida. De otra manera, incrementar en 1 el número n de conjuntos de la variable de entrada y volver al paso c).

Con el algoritmo descrito se consigue un modelo difuso interpretable con una buena precisión y solo se requiere del ajuste de los parámetros del consecuente, que son tipo singleton, lo que disminuye el tiempo de entrenamiento. Es posible lograr una mayor aproximación (“ajuste fino”) si al finalizar el proceso mencionado se aplica el método del gradiente descendiente para ajustar la ubicación de los valores modales de los conjuntos triangulares del antecedente,

conservando la partición suma 1 y, por lo tanto la interpretabilidad del sistema, como explica Espinosa (2005).

#### 4. RESULTADOS

##### *A Control de Profundidad de un ROV*

Se aplicó el método propuesto a la generación de un controlador borroso interpretable, para la regulación de profundidad de un vehículo subacuático operado remotamente ROV, a partir de los datos experimentales de entrada y salidas obtenidos de la regulación realizada por un operador humano.

La figura 3 muestra el control de profundidad realizado por un operador humano que varía la profundidad del ROV desde 0 metros (superficie) hasta 1.70 metros.




Figura 3. Regulación manual de la profundidad de un ROV

El voltaje aplicado al motor de inmersión para realizar el control de profundidad mencionado se muestra en la figura 4.




Figura 4. Voltaje aplicado al motor de inmersión del ROV

Con los datos mostrados en las figuras 3 y 4 se procedió a obtener el controlador mediante identificación borrosa de la acción de control realizado por el experto humano. Se consideraron como variables de entrada valores pasados de el voltaje aplicado  $u(k-2)$  y del error  $e(k-1)$  y como variable de salida la ubicación o profundidad del ROV  $y(k)$ . Para determinar qué valores pasados de las variables de entrada debían ser seleccionados se utilizó el mismo algoritmo de identificación borrosa propuesto, probando con diferentes valores pasados y seleccionado aquel que arrojara la mejor aproximación de acuerdo a una métrica del error (error cuadrático medio).

El controlador difuso obtenido presenta dos funciones de pertenencia triangulares por cada variable de entrada  $u(k-2)$  y  $e(k-1)$ , como se muestra en la figura 5. Esto quiere decir que se generaron 4 consecuentes tipo singleton.. Los conjuntos de ambas variables de entrada fueron etiquetados como Negativo N y Positivo P.




Figura 5. Partición de las variables de entrada del controlador difuso

La proyección de los valores modales generaron los siguientes consecuentes (y por lo tanto las siguientes reglas):

Función de Pertenencia	Ubicación del Consecuente
$u_N(k-2)$	-11.20
$u_P(k-2)$	10.74
$e_N(k-1)$	9.99
$e_P(k-1)$	-11.15

Existen dos consecuentes que se ubican casi en la misma posición lo que nos permite fusionarlos (en un punto intermedio) y reducir el número de reglas, así:

Función de Pertenencia	Ubicación del Consecuente
$u_N(k-2) \Theta e_P(k-1)$	-11.17
$u_P(k-2)$	10.74
$e_N(k-1)$	9.99

Donde  $\Theta$  no es una T-norma sino un operador del tipo promedio.

Luego de hacer el ajuste de consecuentes mediante mínimos cuadrados, el error cuadrático medio alcanzado MSE es de 0.000298. La figura 5 muestra la comparación entre la respuesta del controlador borroso generado y la realizada por el operador humano. Se aprecia que el controlador borroso puede emular con gran precisión la labor realizada por el experto humano.




Figura 5. Comparación entre la respuesta del controlador difuso y la del experto

## 5. CONCLUSIONES

Se presenta un método basado en la minimización del error de inferencia para la identificación de sistemas a partir de los datos, mediante modelos difusos interpretables con ajuste de parámetros consecuentes, tipo singleton, mediante mínimos cuadrados. El método, basado en lógica difusa, no requiere del empleo de otras técnicas de inteligencia artificial.

El método se aplicó para generar un controlador difuso de profundidad de un ROV a partir de los datos generados por la acción de control realizada por un experto humano, Los resultados muestran una alta precisión.

## REFERENCIAS

- [1] Bessa, W. M., Dutra, M. S., Kreuser, E. (2008). “Depth control of remotely operated underwater vehicles using an adaptive fuzzy sliding mode controller”, *Robotics and Autonomous Systems*, vol. 56 , No. 8, pp. 670-677.
- [2] Chen, W., and Saif, M. (2005). “A Novel Fuzzy System With Dynamic Rule Base”, *IEEE Trans. Fuzzy Systems*, **vol. 13**, No. 5, pp.569-582.
- [3] Contreras, J., Misa, R., Murillo, L., (2008). Obtención de Modelos Borrosos Interpretables de Procesos Dinámicos. *Revista Iberoamericana de Automática e Informática Industrial RIAI*. Vol. 5, No. 3, pp. 70-77.
- [4] Contreras, J., Misa, R., Murillo, L., (2007). Interpretable Fuzzy Models from Data and Adaptive Fuzzy Control: A New Approach. In *Proceedings of IEEE International Conference on Fuzzy Systems*. Pags.: 1591-1596. ISBN: 1-4244-1210-2
- [5] Díez J. L., Navarro J. L., Sala A. (2004). Algoritmos de Agrupamiento en la Identificación de Modelos Borrosos. *RIAI: Revista Iberoamericana de Automática e Informática Industrial*.
- [6] Emami, M., Turksen, I., (1998) Goldenberg, A., “Development of a systematic methodology of fuzzy logic modeling. *Transaction of Fuzzy Systems*, **vol. 6**, No. 3, pp.346-360.
- [7] Espinosa, J., Vandewalle, J. (2000), “Constructing fuzzy models with linguistic integrity form numerical data-afreli algorithm”, *IEEE Trans. Fuzzy Systems*, **vol. 8**, pp. 591 – 600.
- [8] Espinosa, J., Vandewalle, J., Wertz, V, *Fuzzy Logic, Identification and Predictive Control*. Springer. Estados Unidos. 2005.
- [9] Gao, R., Kondo, E., Kajiwara, H., Koterayama, W., and Nakamura, M. (2003), “Depth Control of an Underwater Vehicle Using Linear Parameter-varying Techniques”, *International Journal of Offshore and Polar Engineering*, Vol. 13, No. 1.
- [10] Geder, J.D., Palmisano, J., Ramamurti, R., Sandberg, W.C., Ratna, B., (2008), “Fuzzy Logic PID Based Control Design and Performance for a Pectoral Fin Propelled Unmanned Underwater Vehicle”, *International Conference on Control, Automation and Systems 2008*, Seoul, Korea.
- [11] Guillaume, S., Carnomordic, B. (2004), “Generating an interpretable Family of Fuzzy Partitions Form Data”, *IEEE Trans. Fuzzy Systems*, **vol. 12**, No. 3, pp. 324 – 335.

- [12] Guztafson E. E., Kessel W. C. (1979). Fuzzy Clustering with a Fuzzy Covariance Matrix. IEEE CDC, San Diego, California, pp. 503 – 516.
- [13] Joo M.G., and Lee, J.S. (2002) “Universal Approximation by Hierarchical Fuzzy Systems With Constraints on the Fuzzy Rules”, Fuzzy Sets and Systems, 130(2002), pp 175-188.
- [14] Joo M.G., and Lee, J.S. (2005). “A Class of Hierarchical Fuzzy Systems With Constraints on the Fuzzy Rules”, IEEE Trans. Fuzzy Systems, **vol. 13**, No. 2, pp.194-203, 2005.
- [15] Kim. H-S., Shin, Y-K. (2007), “Design of expanded adaptive fuzzy sliding mode controller using FBFE for UFV depth control”, IEEE International Conference on Control, Automation and Systems, 2007. ICCAS '07, pp. 2654-2657.
- [16] Lea, R.K.; Allen, R.; and Merry, S.L. (1999). A comparative study of control techniques for an underwater flight vehicle. International Journal of Systems Science 30(9): pp. 947—964
- [17] Nauck, D., Kruse, R., (1995). "Nefclass - a neuro-fuzzy approach for the classification of data", In Proceedings of the Symposium on Applied Computing.
- [18] Nauck, D., Kruse, R. (1999), “Neuro-fuzzy systems for function approximation”. Fuzzy Sets and System. 101(2), pp. 261-271.
- [19] Paiva, R. P., Dourado, A. (2004), “Interpretability and learning in neuro-fuzzy systems”, Fuzzy Sets and System. 147, pp. 17-38. 2004.
- [20] Pedrycz, W. (1994) Why Triangular Membership Functions?”, IEEE Trans. Fuzzy Sets and System, vol. 64, pp.21-30, 1994
- [21] Sala, A. (1998). Validación y Aproximación Funcional en Sistemas de Control Basados en Lógica Borrosa. Universidad Politécnica de Valencia. Tesis Doctoral.
- [22] Sala, A., Albertos, P. (2001), Inference error minimisation: fuzzy modelling of ambiguous functions. Fuzzy Sets and Systems, 121 pp. 95 – 111.
- [23] Sugeno, M., Yasukawa, T.(1993), “A fuzzy logic based approach to qualitative modeling”. Transactions on Fuzzy Systems, **vol. 1**, No. 1, pp. 7-31. 1993
- [24] Wang, L-X, Mendel, J.M.(1992), “Generating fuzzy rules by learning form examples”, IEEE Transactions on Systems Man and Cybernetics, **vol. 22** ,no 6, pp. 1414-1427.