

Algoritmo para generación de Controladores Difusos Interpretables. Aplicación a un proceso de presión

Juan Antonio Contreras Montes
PhD. en Ciencias Técnicas
Líder Grupo de Investigación en Control,
Comunicaciones y Diseño Naval,
Escuela Naval Almirante Padilla ENAP
Cartagena, Colombia
epcontrerasj@ieee.org

David Javier Muñoz Aldana
Ingeniero Electrónico
Investigador Grupo de Investigación en Control,
Comunicaciones y Diseño Naval,
Escuela Naval Almirante Padilla ENAP
Cartagena, Colombia
daviermual@hotmail.com

Resumen— En este artículo se presenta una novedosa metodología para la generación de controladores difusos tipo singleton a partir de datos experimentales de entrada y salida. Se describe una técnica para construcción de las reglas difusas mediante funciones de pertenencia triangulares, con interpolación en 0.5, para la partición de los antecedentes; mínimos cuadrados para el ajuste de los consecuentes tipo singleton y operadores tipo promedio ponderado, en vez de operadores tipo t-norma. El aspecto más promisorio de la propuesta consiste en la obtención del modelo, o controlador difuso, sin sacrificar su interpretabilidad ni recurrir a otras técnicas de inteligencia artificial. Para llevar a cabo el entrenamiento del controlador difuso se utilizó el sistema de presión del sistema didáctico en control de procesos de Lab-Volt, modelo 6090. Los datos de entrenamiento fueron tomados de una experiencia realizada con un control PI.

Palabras clave— identificación difusa, interpretabilidad, controlador difuso, sistema de presión.

Abstract— A novel approach for the development of linguistically interpretable fuzzy singleton models from experimental data is proposed. The proposed methodology uses triangular sets with 0.5 interpolations. Averaging operator, instead of T-norm operator, is used for combining fuzzy rules. Singleton consequents are employed and least square method is used to adjust the consequents. The most promissory aspect in our proposal consists in achieving model without sacrificing the fuzzy system interpretability. The real-world applicability of the proposed approach is demonstrated by application to a pressure control using the LabVolt Process Control Training System (6090).

Keywords— fuzzy identification, interpretability, fuzzy controller, process pressure.

I. INTRODUCCIÓN

La construcción de modelos difusos involucra la selección y sintonización de varios parámetros como: forma y distribución de las funciones de pertenencia de las variables de entrada, base de

reglas, operadores lógicos empleados, forma y distribución de los consecuentes, entre otros. El gran número de parámetros requeridos para obtener un modelo difuso ha dificultado el desarrollo de una técnica única de modelación, especialmente en el caso de identificación borrosa a partir de datos experimentales de entrada y salida.

Una de las primeras propuestas para diseño automático de sistemas difusos a partir de los datos es la propuesta por Wang [1]. Sugeno y Yasukawa [2] propusieron una metodología para identificación de parámetros de modelos difusos mediante consecuentes tipo *singletons*, pero requiere de muchas reglas y presenta una pobre capacidad de descripción.

Una técnica comúnmente empleada son los algoritmos de agrupamiento difuso, siendo los métodos de Fuzzy C-Means [3], el de Gustafson-Kessel [4] y sus variantes Nauck y Kruse [5] [6] los más empleados. Una metodología interesante para extraer reglas a partir de los datos en un marco de integridad lingüística es presentada por Espinosa y Vandewalle [7]. Sala [8]. [9] introdujo una técnica novedosa basada en el error de inferencia para aproximar funciones con partición suma 1 con conjuntos triangulares, lo cual es un aporte importante a la interpretabilidad de los modelos difusos; Díez *et al.* [10] proponen variaciones a los algoritmos de agrupamiento para mejorar la interpretabilidad y descubrir estructuras afines locales en los modelos difusos obtenidos. Paiva y Dourado [11] 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 con 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 retropropagación, pero impone restricciones en el ajuste de los parámetros y en la fusión de las funciones de pertenencia con el fin de garantizar la interpretabilidad del modelo resultante.

La metodología empleada para mostrar la obtención de controladores difusos tipo *singleton* a partir de datos experimentales de entrada y salida es presentada en dos fases: inicialmente se describe el método de identificación difusa, que indica la estructura empleada para el modelo difuso a obtener, así como el algoritmo de identificación; en la segunda fase, se presenta una aplicación en la cual se genera un controlador difuso a partir de datos experimentales de entrada y salida tomados de un proceso de presión de líquidos regulado por un controlador PI. El objetivo de esta segunda fase no es remplazar al controlador PI con un controlador difuso sino mostrar cómo la técnica de identificación difusa presentada permite generar un controlador a partir de datos experimentales de entrada y salida. De esta manera, será posible construir controladores a partir de datos generados por el control realizado por un experto humano, por ejemplo, y entonces disponer de parámetros (consecuentes *singleton*, funciones de pertenencia, y otros) que puedan ser ajustados para mejorar el desempeño del mismo

II. IDENTIFICACIÓN DIFUSA

A. Estructura del modelo difuso

En la búsqueda de un equilibrio entre la aproximación numérica y la interpretabilidad del sistema difuso resultante se consideran los criterios siguientes para la selección de los parámetros [12]

- 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 concreción [13]; 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 de la clase OWA, cuya denominación obedece a sus siglas en inglés (Ordered Weighted Averaging operators)

- Método de Inferencia

El método de inferencia empleado está dado por

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

donde

$$m_j(x^{(i)}) = u_{A_1^j}(x_1^{(i)}) \cdot u_{A_2^j}(x_2^{(i)}) \cdots u_{A_n^j}(x_n^{(i)}) \quad (2)$$

es el grado de la salida de la j -ésima regla de un sistema difuso tipo Mamdani, $f(x^{(i)})$ es la función que aproxima a la función real de salida, \bar{y}^j es el valor del *singleton* correspondiente a la regla j , A_n^j son los conjuntos difusos del antecedente de la regla j activada, y L corresponde al número de reglas activadas. El grado de salida de cada regla se calcula mediante un operador de combinación de la lógica borrosa de la clase promedio ponderado.

B. Algoritmo de identificación difusa

El algoritmo para generación de sistemas difusos interpretables a partir de los datos se basa en la minimización del error de inferencia. El usuario sólo debe introducir los datos de las variables de entrada y salida y el algoritmo ejecuta las siguientes acciones:

- Determina los rangos de cada variable
- Distribuye las funciones de pertenencia en los universos de cada variable de entrada
- Ubica los consecuentes tipo *singleton* en el espacio de salida
- Determina las reglas y

- Ajusta la ubicación de los consecuentes y emplea mínimos cuadrados, para minimizar el error de aproximación.

El algoritmo se detiene cuando se ha alcanzado una métrica de error menor a la requerida por el usuario o cuando el número de conjuntos difusos por variable de entrada es mayor a 9, para no afectar la interpretabilidad del modelo difuso obtenido [7]. La distribución de las funciones de pertenencia en cada universo de entrada se hace de manera uniforme para garantizar que la partición resultante sea suma 1; es decir, la suma de los grados de pertenencia de un dato en una variable de entrada será siempre igual a 1.

Dado una colección de datos experimentales de entrada y salida $\{x_k^{(i)}, y^{(i)}\}$, con $i = 1 \dots N; k = 1, \dots, p$, donde $x_k^{(i)}$ es el vector de entrada p-dimensional $x_1^{(i)}, x_2^{(i)}, \dots, x_p^{(i)}$ e $y^{(i)}$ es el vector unidimensional de salida, el algoritmo de identificación difusa ejecuta los siguiente pasos

- Organización del conjunto de p variables de entrada y una variable de salida, cada una con N datos.

FIG 1. ORGANIZACIÓN DEL CONJUNTO DE DATOS


$$\begin{bmatrix} x_1^{(1)} \\ x_1^{(2)} \\ \vdots \\ x_1^{(N)} \end{bmatrix} \begin{bmatrix} x_2^{(1)} \\ x_2^{(2)} \\ \vdots \\ x_2^{(N)} \end{bmatrix} \dots \begin{bmatrix} x_p^{(1)} \\ x_p^{(2)} \\ \vdots \\ x_p^{(N)} \end{bmatrix} \rightarrow \begin{bmatrix} y^{(1)} \\ y^{(2)} \\ \vdots \\ y^{(N)} \end{bmatrix}$$

- Determinación de los rangos de los universos de cada variable de acuerdo con los valores máximos y mínimos de los datos asociados , ,
- Distribución de las funciones de pertenencia triangulares sobre cada universo. Se tiene $[x_k^-, x_k^+][y^-, y^+]$

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. Se inicia con n = 2 conjuntos triangulares.

FIG. 2. PARTICIÓN TRIANGULAR SUMA 1. A) PARTICIÓN INICIAL, N=2; B) PARTICIÓN CON N = 5



- Cálculo de los consecuentes *singletons* mediante el empleo del método de mínimos cuadrados. La ecuación (5) puede expresarse de la forma

$$f(x^{(i)}) = \sum_{j=1}^L w_j(x^{(i)})y^j \tag{3}$$

donde

$$w_j(x^{(i)}) = \frac{m_j(x^{(i)})}{\sum_{j=1}^L m_j(x^{(i)})} = w_j^i \tag{4}$$

La ecuación (3) puede expresarse en forma matricial como $Y = W\theta + E$, donde Y representa los valores de salida reales, $W\theta$ representa la salida del modelo difuso, siendo W es la matriz de grados de pertenencia obtenida de (4) y θ el vector de consecuentes, y E es el error de aproximación que debe ser minimizado. Es decir:

$$\begin{bmatrix} y^1 \\ y^2 \\ \vdots \\ y^L \end{bmatrix}_Y = \begin{bmatrix} w_1^1 & w_2^1 & \dots & w_L^1 \\ w_1^2 & w_2^2 & \dots & w_L^2 \\ \vdots & \vdots & \ddots & \vdots \\ w_1^n & w_2^n & \dots & w_L^n \end{bmatrix}_W \begin{bmatrix} \theta^1 \\ \theta^2 \\ \vdots \\ \theta^L \end{bmatrix}_\theta + \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix}_E \tag{5}$$

Empleando la norma del error cuadrático se tiene

$$E^2 = (Y - W\theta)^2 = (Y^2 - 2YW\theta + (W\theta)^2) \tag{6}$$

La solución a este problema de mínimos cuadrados está dada por

$$\frac{\partial E^2}{\partial \theta} = 0 = -2YW + 2W^T W \theta \quad (7)$$

de donde se obtiene

$$\theta = \frac{Y^T W}{W^T W} = (W^T W)^{-1} Y^T W \quad (8)$$

Esta solución es válida si $(W^T W)$ es no singular, lo que quiere decir que todas las reglas deben recibir suficiente excitación durante el entrenamiento. En la práctica esto no es siempre posible, por lo que es recomendable recurrir a la aplicación de mínimos cuadrados recursivos, para garantizar que la adaptación sólo afecte las reglas excitadas e. Validación del modelo mediante el método de

inferencia descrito por (1), donde \bar{y}^j es el valor del *singleton* correspondiente a la regla j .

- f. Terminar si la medida del error cuadrático medio MSE es menor a una medida previamente establecida ó si el número de conjuntos por variable de entrada es mayor a 9. De otra manera, incrementar en 1 el número n de conjuntos de la variable de entrada y volver al paso c).

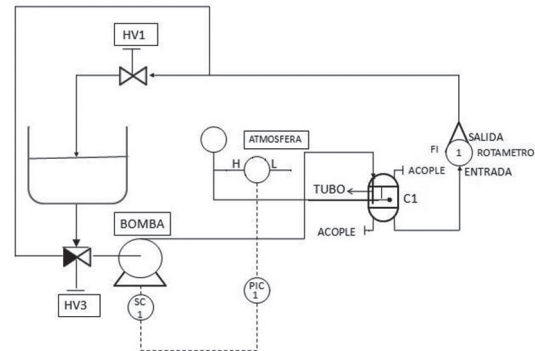
Con el algoritmo descrito se consigue un modelo difuso interpretable que sólo se requiere del ajuste de los parámetros del consecuente, que son tipo singleton, lo que disminuye el tiempo de entrenamiento. La precisión del modelo obtenido es determinada empleando una métrica de error (error cuadrático medio). 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, se conserva la partición suma 1 y, por lo tanto la interpretabilidad del sistema, como explica Espinosa et al. [7].

III. APLICACIÓN Y VALIDACIÓN DEL MÉTODO PROPUESTO

Se ha utilizado el sistema didáctico en control de procesos de Lab-Volt, modelo 6090. El montaje se muestra en la Figura 3, donde HV son las válvulas de operación manual; FI es un indicador de caudal de área variable (rotámetro); SC es el

controlador de velocidad de la bomba, la cual es regulada con voltaje de corriente directa de 0 a 5 voltios, proveniente del PIC, que es el controlador de presión, el cual actualmente en un controlador PI que será remplazado por el controlador difuso; PT es el transmisor de presión, que fue calibrado en el rango de [0, 5] voltios para los rangos mínimo y máximo de presión. C1 es el tanque de almacenamiento.

FIG. 3. SISTEMA DE CONTROL DE PROCESO DE PRESIÓN



Se utilizará el algoritmo de identificación difusa para generar un modelo o controlador difuso que emule la acción del controlador PI implementado en el proceso de control de presión. Inicialmente se desarrolló una experiencia, mediante un controlador PI con banda proporcional del 30% y un T_i de 0.05 min/rpt. Los datos utilizados para el entrenamiento son mostrados en la figura 4. Posteriormente se realizó otra experiencia con variaciones diferentes de la señal de referencia para tomar los datos que se emplearon para la validación, los cuales se muestran en la Figura 5.

FIG. 4. DATOS DE ENTRENAMIENTO. A) VOLTAJE APLICADO A LA BOMBA -; B) REFERENCIA -; C) SALIDA DE PRESIÓN -



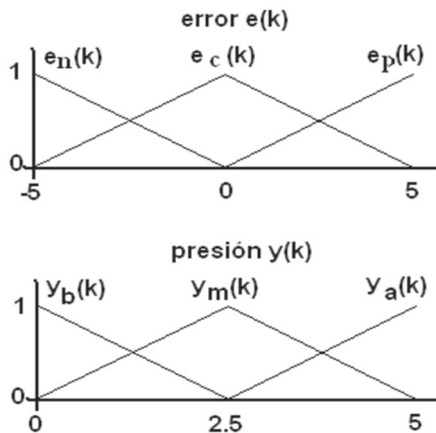


FIG. 5. DATOS DE VALIDACIÓN. A) VOLTAJE APLICADO A LA BOMBA -; B) REFERENCIA -; C) SALIDA DE PRESIÓN -



Se utilizaron como entradas al sistema difuso: las variables error actual $e(k)$, con rango de $[-5, 5]$ y salida de presión actual $y(k)$, con rango $[0, 5]$; y como salida el voltaje aplicado a la bomba $u(k)$, con rango $[0, 5]$. El controlador difuso obtenido tiene tres conjuntos triangulares por variables de entrada; por lo tanto, tiene seis consecuentes tipo singleton, ubicados en $[1.9215 \ 8.677 \ 13.4661 \ -7.01 \ -5.22 \ -4.05]$. Los tres primeros singletons pertenecen a la variable lingüística $e(k)$ y tienen como etiquetas: negativo, cero y positivo; los tres siguientes pertenecen a la variable lingüística $y(k)$ y tienen como etiquetas: bajo, medio y alto. Los conjuntos lingüístico generados son mostrados en la Figura 6.

FIG. 6. PARTICIONES DIFUSAS DE LAS VARIABLES DE ENTRADA ERROR $E(k)$ Y PRESIÓN $Y(k)$.



El error cuadrático medio alcanzado en el entrenamiento fue de 0.0342 y en el proceso de validación fue de 0.04879.

La salida del controlador difuso está dada por $Y=W\theta$, donde


$$W = [u(e_b(k))u(e_m(k))u(e_a(k))u(y_b(k))u(y_m(k))u(y_a(k))]$$

$$\theta(k) = \begin{bmatrix} +1.9215 \\ +8.677 \\ +13.4661 \\ -7.0100 \\ -5.2200 \\ -4.0500 \end{bmatrix}$$

Los consecuentes tipo singleton toman valores que van de un mínimo de -7.0100 a un máximo de $+13.4661$. Los valores negativos se deben etiquetar como valores bajos de voltaje aplicado a la bomba.

La Figura 7 muestra el desempeño del controlador difuso, aplicado al proceso de presión.

FIG. 7. ACCIÓN DEL CONTROLADOR DIFUSO. A) VOLTAJE APLICADO A LA BOMBA -; B) REFERENCIA -; C) SALIDA DE PRESIÓN -



IV. CONCLUSIONES

Se presenta un método para la identificación de sistemas a partir de datos experimentales de entrada y salida, mediante modelos difusos interpretables con ajuste de parámetros consecuentes tipo *singleton* mediante mínimos cuadrados. El método no requiere del empleo de otras técnicas de inteligencia artificial para su entrenamiento y aprende de manera sencilla la acción desempeñada por otro controlador o por un operador humano.

El empleo de consecuentes tipo *singleton* no afecta la interpretabilidad del modelo difuso ya que éstos pueden ser etiquetados de acuerdo con su ubicación en el espacio de salida y con asignaciones de clara comprensión para un operador

humano. Por ser un procedimiento matemático, sin restricciones, el ajuste por mínimos cuadrados puede ubicar los consecuentes por fuera del espacio de salida sin que esto afecte la interpretabilidad.

- [13] Pedrycz, W. Why Triangular Membership Functions?, IEEE Trans. Fuzzy Sets and System, vol. 64, pp.21-30, 1994.

REFERENCIAS

- [1] Wang, L-X, Mendel, J.M., "Generating fuzzy rules by learning form examples", IEEE Transactions on Systems, Man and Cybernetics, vol. 22, No 6, pp. 1414-1427. 1992.
- [2] Sugeno, M., Yasukawa, T., "A fuzzy logic based approach to qualitative modeling". Transactions on Fuzzy Systems, vol. 1, No. 1, pp. 7-31. 1993
- [3] Bezdek J. C. (1987). Pattern recognition with Fuzzy Objective Function Algorithms. Ed. Plenum Press.
- [4] Guztafson E. E., Kessel W. C. Fuzzy Clustering with a Fuzzy Covariance Matrix. IEEE CDC, San Diego, California, pp. 503 - 516.1979.
- [5] Nauck, D., Kruse, R., "Nefclass - a neuro-fuzzy approach for the classification of data", In Proceedings of the Symposium on Applied Computing, 1995.
- [6] Nauck, D., Kruse, R., "Neuro-fuzzy systems for function approximation". Fuzzy Sets and System. 101(2), pp. 261-271. Jan. 1999.
- [7] Espinosa, J., Vandewalle, J., "Constructing fuzzy models with linguistic integrity form numerical data-afreli algorithm", IEEE Trans. Fuzzy Systems, vol. 8, pp. 591 - 600, Oct. 2000.
- [8] Sala, A. (1998). Validación y Aproximación Funcional en Sistemas de Control Basados en Lógica Borrosa. Universidad Politécnica de Valencia. Tesis Doctoral.
- [9] Sala, A., Albertos, P., Inference error minimisation: fuzzy modelling of ambiguous functions. Fuzzy Sets and Systems, 121 (2001) pp. 95 - 111. 2001
- [10] 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.
- [11] Paiva, R. P., Dourado, A., "Interpretability and learning in neuro-fuzzy systems", Fuzzy Sets and System. 147(2004), pp. 17-38. 2004.
- [12] Contreras, J., Misa, R., Paz, J., Building Interpretable Fuzzy Systems: A New Methodology. In proceedings of Electronics, Robotics and Automotive Mechanics Conference CERMA 2006. IEEE Computer Society. Pp.: 172-178. Nov. 2006