

ALGORITMO DE IDENTIFICACIÓN DIFUSA PARA EL MODELADO DE UN TANQUE CALENTADO POR SERPENTIN CON AGITACION CONTINUA

Juan Castillo

Universidad Experimental Politecnica Antonio Jose de Sucre Vicerectorado Puerto Ordaz, Ciudad Guayana,
Venezuela, jpnrz@yahoo.es

Saturno Sarmiento

Universidad Experimental Politecnica Antonio Jose de Sucre Vicerectorado Puerto Ordaz, Ciudad Guayana,
Venezuela, ssarmiento@cantv.net

Alfredo Sanz

Universidad de Zaragoza, Zaragoza, España, asmolina@unizar.es

RESUMEN

En la siguiente investigación, se presentan los resultados alcanzados al implementar una metodología de modelado difuso, sobre un tanque calentado por serpentín con agitación continua. Esta metodología genera automáticamente un modelo difuso Takagi-Sugeno, representado mediante una estructura FIS (Sistema de inferencia difuso), a partir de un conjunto de datos de entrada-salida, empleando para esto el algoritmo de agrupamiento difuso Guftanson-Kessel como una solución óptima para particionar el conjunto de datos disponibles, en subconjuntos caracterizados por un comportamiento lineal local, a partir de los cuales se genera el conjunto de reglas que representan el modelo global. Se realiza una comparación del modelo difuso con 2 modelos obtenidos mediante técnicas de identificación tradicionales como son, un modelo ARX y un modelo en ecuaciones de estado. El algoritmo de identificación difuso se implementó (simuló, validó y comparó) usando Matlab-Simulink V6.5 con sus diferentes ToolBox. Los modelos obtenidos se introdujeron en un esquema de control PID basado en el modelo interno (IMC) el cual fue discretizado mediante el algoritmo de posición para su implementación. Los resultados de las simulaciones establecen las ventajas y desventajas de los algoritmos de identificación analizados observándose que el algoritmo difuso ofrece una respuesta más fiel al proceso real.

Palabras claves: Identificación Difusa, Identificación de Sistemas, Lógica Difusa, Modelado, Sistemas MISO.

ABSTRACT

This investigation presents the results achieved of implementing a fuzzy modelling methodology, on a simulated continue stirred tank heat exchanger. This methodology automatically generates a takagi-sugeno fuzzy model, express in a FIS (fuzzy inference system) structure, from a set of input-output data, next using the Guftanson – Kessel clustering algorithm like an optimal solution to partitioning the available data set, in sub sets characterized by a local linear behavior, from which generates a set of rules that represent the global model. We compare the obtained fuzzy model with 2 linear model obtain from traditional system identification techniques, a ARX model and a State Space model. The fuzzy identification algorithm was simulated, validated, and compared using Matlab-Simulink V.6.5 and different Toolboxes. The obtained models were introduced into a PID control scheme based on internal model control (IMC) which was discretized by the position algorithm. The results of the simulations demonstrate the advantage and disadvantage of the analyzed algorithms, where the fuzzy algorithm presents the most reliable answer to the real process.

Keywords: Fuzzy Identification, System Identification, Fuzzy logic, modeling, MISO System.

1. INTRODUCCION

La obtención de modelos de sistemas reales es cada vez más demandada en diversas áreas de la ciencia y la técnica. Tal es el caso de los procesos industriales y biotecnológicos, los cuales son considerados como sistemas complejos, y de los cuales, por lo general, sólo existe conocimiento parcial obtenido por experiencia operativa.

En la actualidad, existen, de forma madura, dos enfoques principales para modelar: el modelado de Caja Blanca o fundamental, en el cual un modelo dinámico es construido a partir de conocimiento previo y leyes físicas, derivados principalmente en el balance de masa, energía y momento del proceso, y el modelado de Caja Negra o empíricos, basado generalmente en ensayos no destructivos que permiten caracterizar el proceso sin utilizar conocimiento físico, utilizando estructuras lo suficientemente generales “cajas negras” como aproximadores universales de funciones. Es posible combinar ambos enfoques para obtener modelos de Caja Gris o híbridos, utilizando las ventajas de las aproximaciones de caja blanca y caja negra, de forma que las partes conocidas del sistema son modeladas usando principios físicos, y las partes desconocidas o con mas incertidumbre son modeladas usando esquemas de caja negra, empleando datos del proceso y estructuras de modelado de caja negra.

Desde su introducción en 1965 (Zadeh, 1965), la teoría de conjuntos difusos ha encontrado aplicaciones en un amplio rango de disciplinas. El modelado y control de sistemas dinámicos pertenecen a los campos donde estas técnicas han recibido gran atención, no solo de la comunidad científica, sino también de la industria en general.

Un modelo difuso puede ser visto como un modelo lingüísticamente interpretable el cual usa reglas “si-entonces” y operadores lógicos para establecer una composición de sub-modelos locales, los cuales poseen, gracias a los conjuntos difusos, transiciones suaves, y al mismo tiempo hace posible la integración de varios tipos de información dentro de un mismo esquema (Babuska, 1998). Es debido a esta propiedad de integración, que son ideales para formalizar el conocimiento experto, y al mismo tiempo, dadas sus estructuras matemáticas flexibles, pueden representar sistemas no lineales a partir de datos de entrada-salida, haciendo uso efectivo de algoritmos de aprendizajes en combinación con técnicas de regresión convencionales.

En este trabajo se genera automáticamente un modelo difuso del tipo Takagi – Sugeno (TS) a partir de datos de entrada-salida, para lo cual se estudió y comprendió una metodología ya desarrollada, la cual emplea la técnica de agrupamiento difuso Guftanson-Kessel (GK) como una solución optima para particionar el conjunto de datos disponibles, en subconjuntos caracterizados por un comportamiento lineal local, a partir de los cuales se genera el conjunto de reglas que representan el modelo global. También se presentan los resultados y comparaciones entre los modelos obtenidos por el clusterizado difuso y los modelos obtenidos por técnicas de identificación de sistemas tradicionales, auto regresivo con entrada exógena (ARX) y espacio de estados.

El modelado difuso TS ha demostrado ser una técnica ampliamente aceptada y ha sido aplicada en numerosas ocasiones con diferentes algoritmos de agrupamiento difuso, tanto en el modelado de procesos industriales (Quintero, 2003) y (Peña et al, 2002), como en el diseño de técnicas modernas de control basadas en modelos, tales como: sistemas de control predictivo (Abonyi et al, 1999), control adaptativo (Fisher et al, 2002) y sistemas supervisorios y de detección de fallos (Ichtev, 2002).

Los resultados expuestos corresponden a la primera fase de ejecución del proyecto de investigación, los cuales corresponden a la comprensión cabal de un algoritmo de identificación utilizando lógica difusa, mediante la verificación de un modelo ya determinado y su respectiva implementación (simulación, validación, comparación) utilizando las herramientas computacionales Matlab 6.5, con Simulink 5 de Mathworks y sus respectivas Toolboxes de Lógica Difusa, Identificación de Sistemas e Identificación y Modelado Difuso (FMID). (Babuska, 1998).

2. MODELADO DIFUSO.

Se define el modelo Difuso de una planta como una estructura lingüística (conformada por reglas) que permite describir con palabras la dinámica de dicha planta. Se tendrá un buen modelo difuso siempre que se equilibre muy

bien un balance entre exactitud y significado lingüístico.

Dependiendo de la estructura particular del consecuente, 3 tipos de modelos son distinguidos (Babuska, 1998).

Modelo Difuso Lingüístico o Mandami, donde tanto el antecedente como el consecuente son proposiciones difusas.

Modelo Difuso Relacional, el cual se puede entender como una generalización del modelo Lingüístico, permitiendo a una proposición antecedente ser asociada con varias proposiciones consecuentes por medio de una relación difusa.

Modelo Difuso Takagi-Sugeno (TS), donde el consecuente es una función CRIPS de las variables antecedentes en vez de una proposición difusa.

Los modelos Takagi-Sugeno presentan una excelente manera para modelar sistemas no-lineales, descomponiendo estos en una colección de modelos lineales localmente. Los consecuentes individuales son sistemas lineales que pueden ser analizados mediante la teoría de sistemas lineales. Esta investigación esta enfocada a la obtención de modelos difusos del tipo Takagi Sugeno por métodos de clusterizado difuso.

3. ESTRUCTURA MATEMATICA DE LOS MODELOS DIFUSOS TAKAGI – SUGENO (TS).

Un algoritmo de identificación difusa tiene como meta identificar a partir de datos de entrada – salida un sistema no lineal conocido, en el cual el sistema que genera los datos de salida es presumiblemente descrito por:

$$y \approx f(x) \quad (1)$$

Donde la función f captura la dependencia de (y) sobre (x), y el símbolo \approx refleja el hecho de que (y) no será una función exacta de (x). Entonces el modelo identificado representa una función $F(x)$ el cual sirve de aproximación razonable de $f(x)$, no solo para los datos proporcionados sino para el dominio entero X .

El modelo global entero representado por reglas difusas TS queda expresado por:

$$R_i : \text{si } x \text{ es } A_i(x) \text{ entonces } y_i = a_i^T X + b_i, i = 1, 2, \dots, k. \quad (2)$$

$A_i(x)$ representa una función de pertenencia multivariable que describe al conjunto difuso A_i , $x \in R^p$ es la variable de entrada (antecedente), $y_i \in R$ es la salida (consecuente), R_i denota la regla numero i , k es el numero de reglas totales, a_i es un vector de parámetros y b_i un desfase escalar.

Las reglas difusas son inferidas por medio de la siguiente expresión algebraica simple:

$$y = \frac{\sum_{i=1}^k \beta_i(x) * y_i}{\beta_i(x)} \quad (3)$$

Donde $\beta_i(x)$ es el grado de cumplimiento del antecedente, el cual para reglas con conjuntos difusos de antecedentes multivariables es igual al grado de pertenencia de la entrada dada, esto es: $\beta_i(x) = \mu_{A_i}(x)$

4. CLUSTERIZADO DIFUSO PARA LA IDENTIFICACIÓN DEL MODELO TS.

El principio de la identificación por clusterizado de producto espacial es el aproximar un problema de regresión no lineal, descomponiendo este en sub problemas lineales localmente (Abonyi, 2003). Esto se logra particionando el conjunto de datos Z en c clusters.

La mayoría de los algoritmos de clusterizado difuso están basados en la optimización de la función objetivo básica (Abonyi, 2003):

$$J(Z, U, V) = \sum_{i=1}^c \sum_{k=1}^N (\mu_{ik})^m \|z_k - v_i\|_A^2 \quad (4)$$

Donde $U = [\mu_{ik}] \in M_{fc}$ es una matriz partici3n difusa de Z , $V = [v_1, v_2, \dots, v_c]$, $v_i \in \mathbb{R}^n$ es un vector de clusters prototipos (centros), los cuales deben ser determinados, $D^2_{ikA} = \|z_k - v_i\|_A^2 = (z_k - v_i)^T A (z_k - v_i)$ es una norma distancia del producto interno cuadrado y $m \in [1, \infty)$ es el exponente de peso que determina el grado de difusi3n de los clusters resultantes.

Una familia de algoritmos puede ser derivado del esquema b3sico, adaptando la norma de producto interno de (Babuska, 1998), donde se destaca ampliamente el algoritmo Gustafson-Kessel en el cual cada cluster posee su propia matriz de inducci3n de norma A_i , con la siguiente norma de producto interno:

$$D^2_{ikA_i} = (z_k - v_i)^T A_i (z_k - v_i) \quad (5)$$

Utilizando el m3todo de multiplicadores de Lagrange la siguiente expresi3n para A_i es obtenida.

$$A_i = [\rho_i \det(F_i)]^{1/n} F_i^{-1} \quad (6)$$

Donde F_i es la matriz de covarianza difusa del i -esimo cluster definida por:

$$F_i = \frac{\sum_{k=1}^N (\mu_{ik})^m (z_k - v_i)(z_k - v_i)^T}{\sum_{k=1}^N (\mu_{ik})^m} \quad (7)$$

La funci3n objetivo del algoritmo GK esta definida por (Babuska, 1998):

$$J(Z, U, V, A) = \sum_{i=1}^c \sum_{k=1}^N (\mu_{ik})^m D^2_{ikA_i} \quad (8)$$

La minimizaci3n de (Abonyi, 2003) se resuelve a por medio del algoritmo GK:

Dado un conjunto de datos Z , se escoge el numero de clusters $1 < c < N$, el exponente de pesos $m > 1$, la tolerancia de finalizaci3n $\varepsilon > 0$ y la matriz normalizada inducida A . Se inicializa la matriz de partici3n aleatoriamente de tal forma que $U^0 \in M_{fc}$.

Repetir para $l = 1, 2, 3, \dots$

Paso 1: Calcular los clusters prototipos (medios):

$$v_i^{(l)} = \frac{\sum_{k=1}^N \left(\mu_{ik}^{(l-1)} \right)^m z_k}{\sum_{k=1}^N \left(\mu_{ik}^{(l-1)} \right)^m}; 1 \leq i \leq c$$

Paso 2: Calcular la matriz de covarianza del cluster:

$$F_i = \frac{\sum_{k=1}^N \left(\mu_{ik}^{(l-1)} \right)^m (z_k - v_i^{(l)})(z_k - v_i^{(l)})^T}{\sum_{k=1}^N \left(\mu_{ik}^{(l-1)} \right)^m}; 1 \leq i \leq c$$

Paso 3: Calcular las distancias:

$$D_{ikAi}^2 = \left(z_k - v_i^{(\ell)} \right)^T \left[[\rho_i \det(F_i)]^{1/n} F_i^{-1} \right] \left(z_k - v_i^{(\ell)} \right)$$

$$; 1 \leq i \leq c, 1 \leq k \leq N$$

Paso 4: Actualizar la matriz de partición:

Si $D_{ikAi} > 0$ para $1 \leq i \leq c, 1 \leq k \leq N$

$$\mu_{ik}^{(\ell)} = \frac{1}{\sum_{j=1}^c \left(\frac{D_{ikAi}}{D_{jkAi}} \right)^{\frac{2}{m-1}}}$$

De lo contrario

$$\mu_{ik}^{(\ell)} = 0 \text{ SI } D_{ikAi} > 0, \text{ Y } \mu_{ik}^{(\ell)} \in [0,1] \text{ CON } \sum_{i=1}^c \mu_{ik}^{(\ell)} = 1.$$

Hasta $\|U^{(\ell)} - U^{(\ell-1)}\| < \epsilon$

Las reglas TS son expresadas de la siguiente forma:

$$R_i : \text{si } x_1 \text{ es } A_{i1} \text{ y } \dots \text{ y } x_p \text{ es } A_{ip} \text{ entonces } y_i = a_i^T x + b_i, i = 1, \dots, K \quad (9)$$

La Figura 1 muestra un resumen de los pasos individuales a seguir en el proceso de identificación, el cual es iterativo por naturaleza. En una sesión de modelado típica, varios de los pasos deben ser repetidos al escoger diferentes casos de varios de sus parámetros

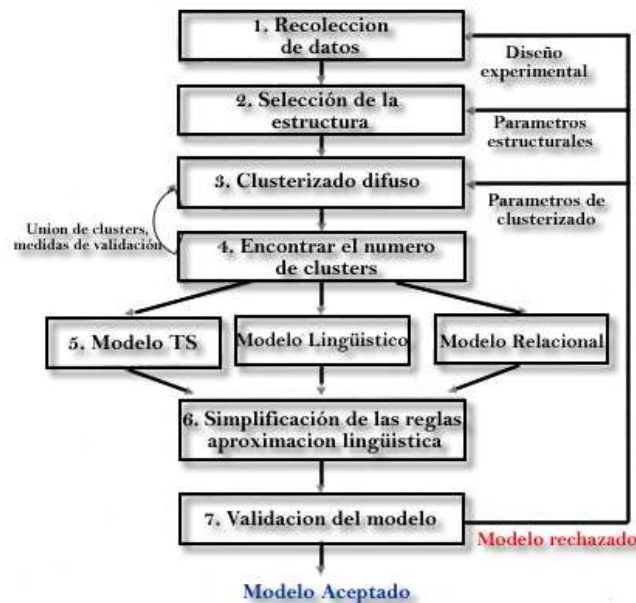


Figura 1 : Resumen del proceso de identificación basado en algoritmos de clusterizado difuso.

5. APLICACIÓN DE LA METODOLOGÍA ESTUDIADA AL MODELADO DE UN TANQUE CALENTADO POR SERPENTIN CON AGITACION CONTINUA.

El proceso industrial seleccionado para la implementación de la metodología descrita, es un tanque calentador con agitación continua (CSTR), en el cual se utiliza un modelo matemático no lineal como aproximación al sistema

real, cumpliendo así con los objetivos planteados. Para el estudio se usó Matlab - Simulink de *Mathworks*.

Primero se construyó un modelo difuso a partir de datos de entrada – salida, utilizando la Toolbox de Identificación y Modelado de Sistemas de MATLAB (Babuska, 1998) la cual implementa el algoritmo GK.

Luego se construyeron dos modelos lineales, a partir del mismo juego de datos de I/O; para ello se utilizó la Toolbox de Identificación de Sistemas de MATLAB (Ljung, 2005), para obtener un modelo lineal ARX de 4° orden y un modelo de Espacio de Estados de 2° orden, esto con el fin de compararlos con el modelo difuso.

Se diseñó un controlador PID basado en el modelo interno (IMC) según (Sarmiento, 2004), el cual se discretizó por medio del algoritmo de posición (Sarmiento, 2002) para su implementación en la simulación de validación. El diagrama general de la fase de recolección de datos usado en el proceso de identificación se observa en Figura 2, donde podemos observar las 3 entradas de excitación, la válvula y el sensor – transmisor, las variables de adquisición de las entradas y salidas (azul), el proceso como tal y un cuadro que ofrece más información sobre dicho proceso (verde).

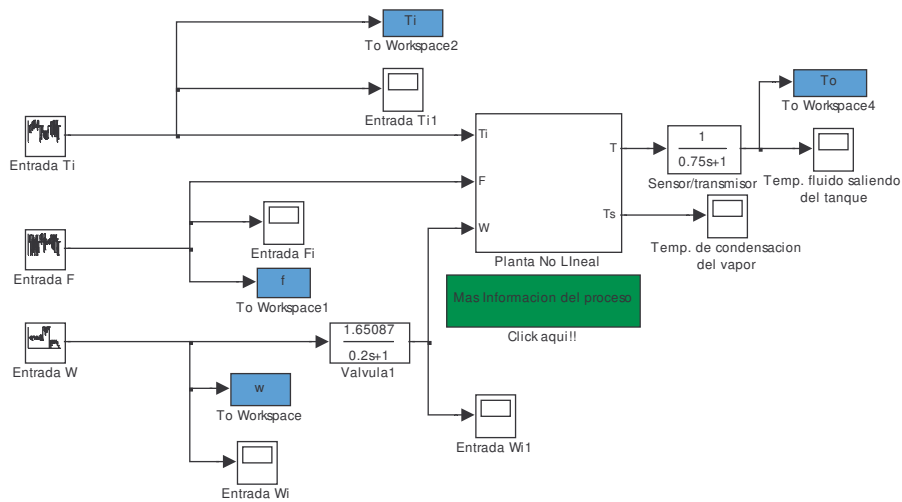


Figura 2 Diagrama de bloques del experimento de identificación.

5.1 DESCRIPCIÓN DEL PROCESO.

El proceso en estudio es un Tanque Calentado por serpentín con agitación continua, del cual se disponen las ecuaciones dinámicas que lo modelan y los datos necesarios para hallar las funciones de transferencia en S que describen al sensor – transmisor y a la válvula. Un diagrama P&ID del tanque calentador con agitación continua se muestra en la Figura 3.

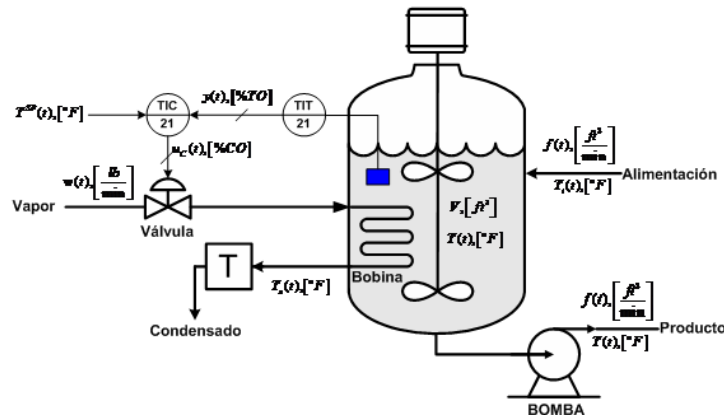


Figura 3 Diagrama P&ID del proceso en estudio.

Este sistema es usado para calentar un fluido de proceso tal que sus componentes premezclados logren una composición uniforme. El control de temperatura de este sistema es importante porque una alta temperatura tiende a descomponer el producto, mientras que una baja temperatura resulta en un mezclado imperfecto. El tanque es calentado usando vapor condensado que circula dentro de una bobina (serpentín de vapor).

Luego de realizar un balance de materia y energía sobre el líquido del tanque y sobre la bobina (Sarmiento, 2004b) se obtienen las ecuaciones dinámicas del proceso, las cuales se indican en (12) y (13).

$$V\rho C_v \frac{dT(t)}{dt} = F(t)\rho C_p T_i(t) + UA[T_s(t) - T(t)] - F(t)\rho C_p T(t) \quad (12)$$

$$C_M \frac{dT_s(t)}{dt} = w(t)\lambda - UA[T_s(t) - T(t)] \quad (13)$$

Donde:

V = Volumen: longitud³

ρ = Densidad: masa/volumen

C_v = Capacidad calorica del fluido a volumen Ctte

C_p = Capacidad calorica del fluido a presion Ctte

$T(t)$ = Temperatura del fluido saliendo del tanque (°F)

$T_i(t)$ = Temperatura del fluido entrante (°F)

$T_s(t)$ = Temperatura del vapor (°F)

$F(t)$ = Rata de flujo volumetrico del sistema (ft³/min)

U = Coeficiente de transferencia de calor general

A = Area para la transferencia de calor

C_M = Capacidad calorica del metal de la bobina

$w(t)$ = Rata de vapor (lb/min)

λ = Calor latente de condensación

El sensor/transmisor de temperatura ha sido calibrado en un rango de 100 a 200 °F, su función de transferencia es:

$$H(s) = \frac{1}{0.75 S + 1} \quad (14)$$

La función de transferencia de la válvula de control se ha estimado como:

$$G_v(s) = \frac{1.65087}{0.2 S + 1} \quad (15)$$

Para medir el desempeño de los modelos se calculó la contabilidad de variación (VAF) y el error cuadrático medio (RMSE), para tener un criterio de comparación adicional al análisis grafico. Estos criterios están definidos como:

$$VAF = 100\% \left[1 - \frac{\text{var}(y - y_m)}{\text{var}(y)} \right] \quad (16)$$

$$RMSE = \sqrt{\frac{(y - y_m)^2}{N^\circ \text{muestras}}} \quad (17)$$

El VAF de dos señales iguales es 100%. Si las señales difieren, el VAF decrece, un valor de $RMSE$ cercano a 0 (cero), indica una mayor igualdad entre las señales.

5.2 CONSTRUCCIÓN Y VALIDACIÓN DE LOS MODELOS.

Como señales de excitación se eligieron señales de sumas de escalones de diferentes amplitudes y diferentes

periodos (Godfrey, 1993), que produjeran salidas alrededor del punto de operación para cada una de las 3 entradas del proceso (Temperatura de entrada, Flujo y Vapor), de modo que se lograra excitar al sistema en el mayor rango de amplitudes y frecuencias posibles. Estas entradas y las salidas correspondientes del sistema se observan en la Figura 4 .

El conjunto de datos de identificación esta conformado por 3000 muestras obtenidas con un periodo de muestreo de 0.1 min. El modelo del proceso identificado esta compuesto por el conjunto válvula + planta + (sensor – transmisor).




Figura 4 Conjunto de entradas y la salida producida por el sistema.

Se obtuvo un modelo difuso con un $VAF = 98.6126$, con 5 cluster. Las funciones de pertenencia de los antecedentes se generó por el método de proyección ortogonal, los parámetros consecuentes se generaron a través del método de los mínimos cuadrados globales.

El orden del numerador, denominador y el retardo de transporte de la estructura Takagi-Sugeno NARX a la que se aproxima cada cluster, nos da un modelo difuso con la siguiente estructura $y(k+1) = f[y(k), u(k)]$ y reglas.

1. Si $Tempsaliendo(k-1)$ es A_{11} y $Tempentrando(k-1)$ es A_{12} y $Flujo(k-1)$ es A_{13} y $Vapor(k-1)$ es A_{14} entonces $Tempsaliendo(k) = 0.926Tempensaliendo(k-1) + 0.180Tempentrando(k-1) - 0.261Flujo(k-1) + 0.24Vapor(k-1) - 6.09$
2. Si $Tempsaliendo(k-1)$ es A_{21} y $Tempentrando(k-1)$ es A_{22} y $Flujo(k-1)$ es A_{23} y $Vapor(k-1)$ es A_{24} entonces $Tempsaliendo(k) = 0.942Tempensaliendo(k-1) + 0.0932Tempentrando(k-1) - 0.282Flujo(k-1) + 0.182Vapor(k-1) - 1.13$
3. Si $Tempsaliendo(k-1)$ es A_{31} y $Tempentrando(k-1)$ es A_{32} y $Flujo(k-1)$ es A_{33} y $Vapor(k-1)$ es A_{34} entonces $Tempsaliendo(k) = 0.209Tempensaliendo(k-1) - 2.80Tempentrando(k-1) - 0.741Flujo(k-1) - 12.1Vapor(k-1) + 720$
4. Si $Tempsaliendo(k-1)$ es A_{41} y $Tempentrando(k-1)$ es A_{42} y $Flujo(k-1)$ es A_{43} y $Vapor(k-1)$ es A_{44} entonces $Tempsaliendo(k) = 0.938Tempensaliendo(k-1) + 0.0818Tempentrando(k-1) - 0.522Flujo(k-1) + 0.246Vapor(k-1) + 2.25$
5. Si $Tempsaliendo(k-1)$ es A_{51} y $Tempentrando(k-1)$ es A_{52} y $Flujo(k-1)$ es A_{53} y $Vapor(k-1)$ es A_{54} entonces $Tempsaliendo(k) = 0.917Tempensaliendo(k-1) + 0.0691Tempentrando(k-1) - 0.765Flujo(k-1) + 0.192Vapor(k-1) + 11.1$

A continuación se procedió a simular en conjunto los 3 modelos (el no lineal, el ARX y el de Espacio de Estado) junto al modelo difuso y de esta forma comparar las respuestas de los sistemas.

El desempeño de los modelos se observa gráficamente en la Figura 5 y numéricamente en la **Error! Reference source not found.** Todos los resultados están en función de su desempeño en relación al modelo real (Modelo No Lineal – color negro).




Figura 5 Salida de los modelos identificados en comparación con el real.

Tabla 1 Desempeño de los modelos ante las entradas de excitación.

Modelo	VAF(%)	RMSE
EC. de estado 2º orden	63.5002	16.3588
ARX 4º orden	63.4915	16.4220
Lógica Difusa	97.1034	4.5218

Se puede apreciar gráficamente y numéricamente que el desempeño del modelo difuso esta muy por encima de los modelos lineales obtenidos por técnicas de identificación tradicionales.

Se realizaron pruebas de desempeño de los modelos al ser manejados por una señal de control, proveniente de un controlador PID diseñado bajo el esquema de control IMC, para un sobrepaso menor al 5%, ante cambios en la referencia. Dicho controlador se discretizó usando el método del algoritmo de posición, el cual emplea la Integral trapezoidal + Derivada Anterior; dicha discretización se implementó en un subsistema de SIMULINK y se aplico a todos los modelos por igual. La Figura 6 muestra el diagrama de dicha simulación, la Figura 7 muestra la respuesta de los modelo y la **Error! Reference source not found.** el desempeño numérico, donde se aprecia la fidelidad del modelo difuso.

Tabla 2 Desempeño de los modelos ante cambios en la referencia, compensado con el controlador PID.

Modelo	VAF(%)	RMSE
EC. de estado 2º	87.3108	8.2206
ARX 4º	65.7993	13.4956
Lógica Difusa	95.3474	4.9776

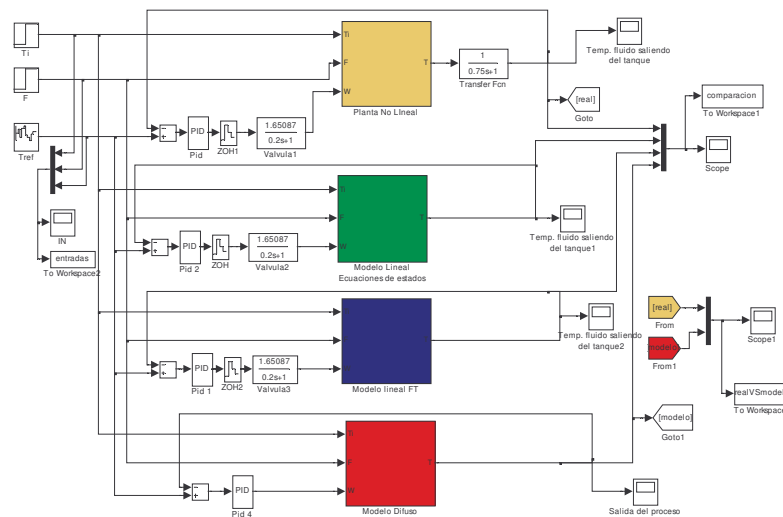


Figura 6 Diagrama en Simulink para la simulación de los diferentes modelos junto al controlador PID.




Figura 7 Salida de los modelos ante cambios en la referencia, compensados con el controlador PID.

6. CONCLUSIONES

Se estudio y comprendió una herramienta de clusterizado difuso, la cual permitió crear modelos difusos del tipo Takagi – Sugeno, a partir de un conjunto de datos de entrada – salida. Se obtuvieron resultados mediante simulación, al modelar por distintas vías un Tanque calentador con agitación continua, demostrándose a través de los resultados el desempeño superior del modelo difuso sobre los 2 modelos lineales obtenidos por métodos convencionales.

Futuros trabajos bajo esta misma línea de investigación: aplicación de la metodología expuesta sobre un proceso físico real existente, diseño de un controlador difuso basado en el modelo difuso encontrado, estudio de nuevas herramientas para integrar conocimiento del proceso sobre el modelo difuso obtenido.

Autorización y Renuncia

Los autores autorizan a LACCEI para publicar el escrito en los procedimientos de la conferencia. LACCEI o los editors no son responsables ni por el contenido ni por las implicaciones de lo que esta expresado en el escrito

REFERENCIAS.

- L. A. Zadeh. "Fuzzy Sets", Information and Control, vol. 8, pp 338-353, 1965.
- R. Babuska. "Fuzzy Modeling for Control", Kluwer Academic Publishers, Boston, 1998.
- L. Quintero, "Modelamiento e identificación Takagi – Sugeno de un intercambiador de calor" Universidad Nacional de Colombia, sede de Medellín, Medellín Colombia, 2003.
- M. Peña, R Carelli, F Di Sciascio. "Identificación de sistemas con un modelo borroso del tipo Takagi – Sugeno", Instituto de automática, Facultad de Ingeniería, Universidad de San Juan, Argentina, 2002.
- R. Babuska, J Abonyi, H.B. Verbruggen, F Szeiferf. "Incorporating prior knowledge in fuzzy model identification", Delft University of Technology, Holanda, University of Veszprem, Hungria, 1999.
- M Fisher, O Nelles, A Fink. "Adaptative Fuzzy Model – Based Control", Darmstadt University of Technology, Alemania, 2002.
- A Ichtev. "Multiple Fuzzy Models for Fault Tolerant Control" , Technical University of Sofia , Bulgaria , 2002.
- J. Abonyi. "Fuzzy Model Identification for Control", Birkhäuser, Boston, 2003.
- S. Sarmiento, "Guía de estudio de Teoría de Control", Ciudad Guayana, Venezuela, 2004.
- S. Sarmiento, "Guía de Estudios de Control Digital", Ciudad Guayana, Venezuela, 2002.
- S. Sarmiento, "Modelado fundamental, Análisis Dinámico y de estado estable de procesos industriales". Guía de estudio de Control de Procesos Industriales, Ciudad Guayana, Venezuela, 2004.
- K. Godfrey. "Perturbation signals for system identification". Prentice Hall, New York, 1993.
- L Ljung, "The System Identification Toolbox: The Manual". The Mathworks Inc. 2005.
- "Fuzzy Logic Toolbox for Matlab User's Guide", The Mathworks Inc, 2005.