

## **Diseño de un IMC no lineal utilizando redes neuronales**

**Johanny Niño Fonseca, jfninof@unal.edu.co<sup>1</sup>**

**Fabio Sierra Vargas, fesierrav@unal.edu.co<sup>2</sup>**

<sup>1</sup> Univerisidad Nacional de Colombia

<sup>2</sup> Univerisidad Nacional de Colombia

**Resumen:** En este artículo se describe la implementación de un IMC (Internal Model Control) no lineal en un intercambiador de calor de placas. Para el desarrollo del IMC, se utilizan dos modelos no lineales uno para representar la planta y otro para la inversa de la misma (controlador), los dos sistemas son implementados mediante redes neuronales supervisadas tipo perceptron multicapa y son entrenadas con la técnica de propagación inversa. Su funcionamiento se compara con el de un control tipo PID sintonizado mediante el método de Ziegler – Nichols. Las pruebas que se realizaron, muestran un comportamiento adecuado del IMC ante diferentes puntos de referencia mostrando una mayor estabilidad ante cambios bruscos en el nivel de referencia.

**Palabras-clave:** Control por modelo interno (IMC), intercambiador de calor de placas (ICP), perceptron multicapa, propagación inversa, redes neuronales (NN)

### **1. INTRODUCCIÓN**

Los sistemas de control PID son una combinación de tres acciones, la proporcional, la integral y la derivativa, las cuales, sintonizadas de forma correcta son suficiente para solucionar muchos de los problemas de control que existen y en la actualidad estos controles están siendo usados en más del 95% de los lazos de control que existen en la industria. A pesar de que han sobrevivido a diferentes cambios tecnológicos y que eliminan el error en estado estacionario mediante la realimentación (siendo está una de sus mayores ventajas), el ajuste de los controladores PID es un trabajo tedioso y requiere de cierto grado de intuición basado en los principios de funcionamiento, tanto de los procesos físicos controlados, como de la teoría de control, por lo que para algunas aplicaciones es preferible usar controles inteligentes.

Los controles inteligentes son aquellos que tienen la habilidad de actuar apropiadamente en un entorno con incertidumbre, donde una acción apropiada es la que aumenta la probabilidad de consecución de los objetivos del sistema mediante actividades adaptativas, fusionando así los métodos matemáticos y los métodos cognoscitivos (lingüísticos). Los controles inteligentes más desarrollados en la actualidad están basados en sistemas expertos tales como: la lógica difusa, las redes neuronales y los algoritmos genéticos.

Dentro de los sistemas expertos, las redes neuronales han sido ampliamente utilizadas en la identificación de procesos o como sistemas que optimizan el funcionamiento de un controlador, su principal habilidad es la de aproximar con gran precisión funciones no lineales mediante entrenamiento con pares de datos de entrada-salida. Existen diferentes modelos de control neuronal tales como: los controles neuronales indirectos, los controles neuronales directos, los controles adaptativos para sistemas no lineales entre otros [1], [2], [3].

### **2. CONTROL IMC NO LINEAL**

El IMC es un método adaptativo especial para sistemas no lineales que ha venido ganando gran aceptación debido a su capacidad para rechazar perturbaciones, sus favorables propiedades de robustez, su sencillez en el diseño y su fácil sintonización. Este tipo de control está ampliamente fundamentado por diversos autores desde la teoría para sistemas lineales, sin embargo, la mayoría de los sistemas reales presentan algún tipo de no linealidad, por lo que se hace necesario extender este método para sistemas no lineales mediante el uso de sistemas expertos como las redes neuronales multicapa con entradas tipo NARMAX.

Los IMC se obtienen mediante el uso de dos operadores: el del modelo de la planta  $M$  y el de la inversa de la misma  $C$ . Debido a que en sistemas no lineales,  $C$  no representa exactamente la inversa de la planta, se genera en el lazo una señal de error no nula que puede afectar el desempeño del control hasta deteriorarse o incluso hacerse inestable, por

lo que se añade un filtro robusto **F** que permite eliminar este efecto. El esquema del control IMC se muestra en la Figura 1, allí se puede notar la señal de salida del controlador “**u**”, la salida del filtro “**x**”, la salida de la planta “**y**” y la salida del modelo “**y'**”.

Un control IMC posee propiedades elevadas de estabilidad y robustez las cuales pueden ser analizadas y manipuladas fácilmente, incluso en sistemas no lineales. Un control IMC no lineal (N-IMC) difiere en que los IMC en la linealidad o no de los operadores **M** y **C**. Un control IMC cumple con las siguientes propiedades:

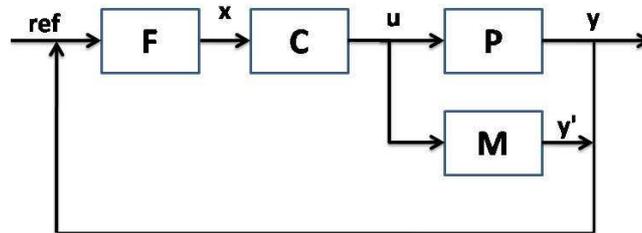


Figura 1. Esquema general de un controlador IMC

**Propiedad 1.** Si el controlador **C** y la planta **P** son estables y el modelo de la planta **M** es una representación perfecta de la misma, entonces el sistema es estable.

**Propiedad 2.** Si existe el operador inverso del modelo de la planta  $M^{-1}$  y se utiliza como controlador ( $M^{-1} = C$ ), si el sistema es estable, entonces el controlador es perfecto y no requiere filtro robusto.

**Propiedad 3.** Si se cumplen las propiedades anteriores, se obtiene un control sin estado transitorio, siempre que las entradas estén asintóticamente distribuidas.

**OPERADOR M.** Es un modelo del comportamiento de la dinámica de la planta. Cuando el sistema (la planta) presenta un comportamiento no lineal, resulta adecuado usar sistemas expertos como las redes neuronales o métodos de lógica difusa [4].

**OPERADOR C.** Es la inversa del comportamiento de la dinámica de la planta y su función es actuar como controlador del sistema. La estimación de la inversa cuando **M** es lineal, es directa, mientras que cuando son modelos no lineales, el cálculo de la inversa no siempre es posible ya que puede ser sensible a ruidos y a errores numéricos [5].

**OPERADOR F.** Debido a que el operador **M**, está sometido a algún tipo de error en estado estacionario y no representa exactamente el comportamiento de la planta, es necesario incluir un filtro que permita reducir el error y así dotar al sistema de robustez [6].

### 3. REDES NEURONALES ARTIFICIALES

Las redes neuronales se pueden entender como una caja negra que permite representar modelos altamente no lineales a un bajo costo computacional y con una alta precisión. Existen diferentes tipos de redes neuronales y múltiples aplicaciones se han desarrollado en cada caso [7]. Las redes neuronales artificiales están basadas en el comportamiento del cerebro humano y cada una de ellas está compuesta por un núcleo (unidad de procesamiento), dendritas (puntos de entrada de la información), el axón (canal de salida de la información) y se pueden observar en la Figura 2.

**Las neuronas son consideradas unidades de procesamiento simple y se caracterizan porque el procesamiento que tienen es altamente paralelo, distribuido y adaptativo [8], [9]. Dentro de los modelos neuronales más conocidos están las perceptron (**

Figura 3), perceptron multicapa, madeline, hopfield y neocognitron. Dado su amplio uso en sistemas de control robusto, en el desarrollo de esta investigación se utiliza la red neuronal perceptron multicapa con una sola capa oculta, debido a que es adecuada para representar modelos no lineales con bastante precisión [5], [7].

Una red perceptron multicapa notada como **[N|M|L]**, indica que tiene **N** variables de entrada, **M** neuronas ocultas y **L** variables de salida. Dadas las **N** variables de entrada  $x_i$ , se define el vector de entrada a la matriz como:

$$\mathbf{x}_i = [x_1, x_2, \dots, x_N, 1]$$

Al cual se le agrega un escalar de valor 1 en la última posición del vector para facilitar el manejo matricial. Los pesos a la entrada  $w_{i,j}$  y la salida  $z_{j,k}$  de la red indican la intensidad de la conexión que existe entre cada neurona de la entrada a la capa oculta y de la capa oculta a la salida, se definen matricialmente como:

$$W_{i,j} = \begin{bmatrix} W_{11} & W_{12} & \dots & W_{1N} \\ W_{21} & W_{22} & \dots & W_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ W_{N1} & W_{N2} & \dots & W_{NN} \\ \theta_{11} & \theta_{12} & \dots & \theta_{1N} \end{bmatrix}$$

$$z_{j,k} = \begin{bmatrix} z_{11} & z_{12} & \dots & z_{1L} \\ z_{21} & z_{22} & \dots & z_{2L} \\ \vdots & \vdots & \ddots & \vdots \\ z_{M1} & z_{M2} & \dots & z_{ML} \\ \theta_{21} & \theta_{22} & \dots & \theta_{2L} \end{bmatrix}$$

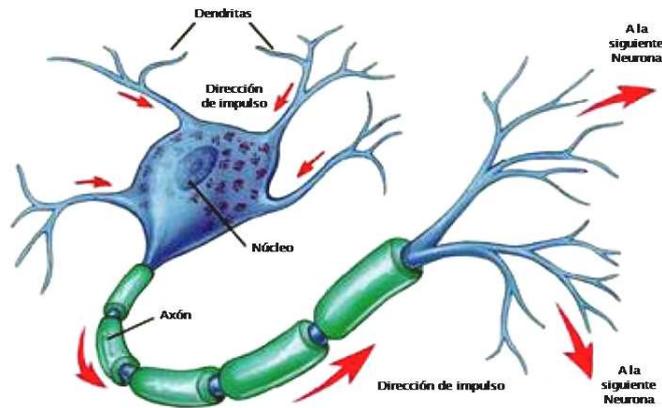


Figura 2. Elementos que forman una red neuronal biológica [4]

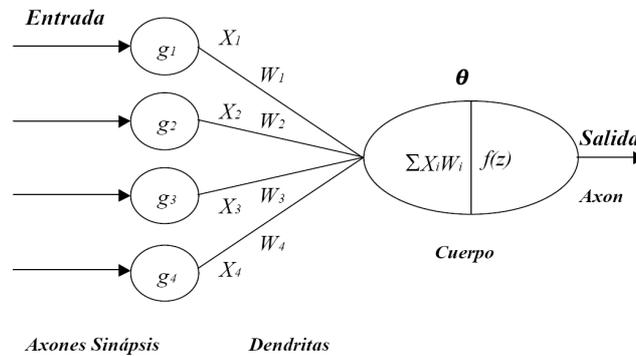


Figura 3. Esquema de una red neuronal tipo perceptron

La salida  $u_j$  de cada una de las neuronas de la capa oculta de la red se expresa como:

$$u_j = [f(x_1 \cdot w_{1,j}), f(x_2 \cdot w_{2,j}), \dots, f(x_N \cdot w_{N,j}), f(1 \cdot \theta_{1,j}), 1]$$

Donde  $f$  es una función de activación que ajusta las salidas dándoles una ponderación entre 0 y 1 en cada caso. Existen diferentes funciones de activación, entre ellas la función lineal, la escalón, la sigmoidea, la gaussiana [5].

Las L salidas de la red neuronal se pueden obtener como:

$$y_k = [f(w_1 \cdot z_{1,k}), f(w_2 \cdot z_{2,k}), \dots, f(w_M \cdot z_{M,k}), f(1 \cdot \theta_{1,k})]$$

El entrenamiento es la etapa en la que la red es ajustada mediante técnicas iterativas al comportamiento del sistema,

existen diferentes métodos que se pueden clasificar en supervisados cuando el entrenamiento se hace en línea y durante el proceso, estos métodos no han tenido acogida dentro de los sistemas de control debido a que son inestables ante eventos transitorios del sistema. El entrenamiento no supervisado o fuera de línea requiere una detallada información del comportamiento de la planta, lo cual, si logra incluir los diferentes puntos de funcionamiento, puede ser suficiente para obtener un modelo adecuado para el sistema [5].

Para verificar el comportamiento de la red, se hace una simulación de la misma, para esto generalmente se toma un 20% a 30% del total de los datos adquiridos para el entrenamiento y se verifican comparando el error entre la salida simulada y la real, con el fin de asegurar el comportamiento en condiciones reales.

#### 4. IMPLEMENTACIÓN DEL IMC EN UN INTERCAMBIADOR DE CALOR DE PLACAS

Un intercambiador de calor es un dispositivo usado para transmitir calor entre dos fluidos que pueden estar separados mediante una barrera sólida o que se encuentren en contacto directo. Un intercambiador de calor de placas ICP es un conjunto de láminas separadas por un empaque y entre cada cavidad formada, se alternan los dos fluidos que transfieren energía entre sí. Las placas tienen preformas que hacen que se aumente el área de transferencia con lo cual son más eficientes que los intercambiadores de carcasa y tubos que son también ampliamente utilizados a nivel industrial. En el laboratorio de ciencias térmicas de la Universidad Nacional de Colombia, se encuentra un ICP didáctico construido en 1999 bajo la tesis [8], [9] (Figura 4), el cual puede configurar el sentido del flujo en diferentes direcciones como en U ascendente o descendente y en Z ascendente o descendente. Para las diferentes pruebas se utilizó la configuración en U descendente.



Figura 4. ICP usado en el desarrollo de la experimentación.

Como se mencionó anteriormente, el equipo intercambia calor entre dos fluidos, el *fluido 1* es agua fría a temperatura ambiente que proviene de una torre de enfriamiento y que después de circular por el ICP retorna a la torre por un canal paralelo, el *fluido 2* es agua que se almacena en un tanque y se calienta dentro del mismo con seis resistencias de 1500W cada una, el agua es impulsada mediante una motobomba de 0.5 HP trifásica, la cual es regulada mediante un variador de frecuencia a 40 Hz, debido a que por el diseño del equipo requiere un menor caudal en la línea al que suministra la misma [8].

El caudal de entrada del fluido 2 es controlado mediante una válvula proporcional neumática de diafragma, la cual recibe una señal neumática de 3 a 15 psi y desplaza el vástago de apertura en función de dicha señal. La señal neumática se obtiene mediante un transductor IP, que recibe una señal de corriente de 4 a 20 mA y genera una señal neumática de 3 a 15 psi de forma proporcional.

En la Figura 5, se muestra la apertura de la válvula en función de la corriente de entrada, se observa que durante el aumento de corriente el sistema es proporcional, mas sin embargo, cuando desciende la corriente, la válvula presenta una histéresis mecánica producto del resorte que tiene internamente con lo que no hay una correspondencia directa entre la corriente y la posición generando una falla en la sintonización del controlador PID y el IMC. En la Figura 6, se muestra el cambio del caudal en función de la corriente que se le aplica al transductor IP en un ciclo de subida.

Para corregir la histéresis, se implemento en LabVIEW, una función que obtiene la corriente del transductor a partir de la posición deseada y la posición anterior como:

$$COR = a_1 \cdot POS + a_2 + \frac{POS - POS1}{|POS - POS1|} a_3$$

Donde:

- COR: corriente a aplicar [mA]
- POS: posición deseada [mil]
- POS1: posición de la válvula [mil]
- a<sub>1</sub>, a<sub>2</sub> y a<sub>3</sub>: constantes

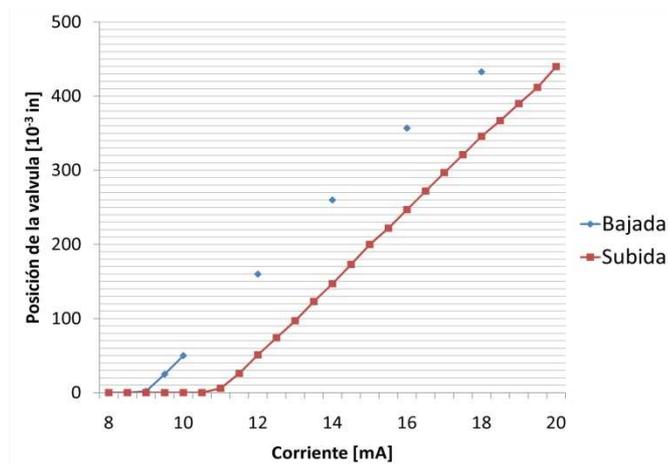


Figura 5. Comportamiento de la válvula en función de la señal de corriente

A partir de regresiones lineales en Excel, se obtuvieron los siguientes valores para las constantes para la válvula:

$$a_1 = 0.020737$$

$$a_2 = 9.917052$$

$$a_3 = 0.958526$$

El esquema del sistema de control y adquisición de datos se muestra en la

Figura 7, fue implementado en LabVIEW el software para la adquisición de datos de la curva de respuesta al escalón, el control PID y el IMC. El hardware que se utilizo es un chasis USB-NI-9172 que cuenta con dos tarjetas de adquisición de temperatura NI-9211 para termocuplas tipo J y K, además, una tarjeta NI-9265 que genera corriente entre 0 y 20 mA.

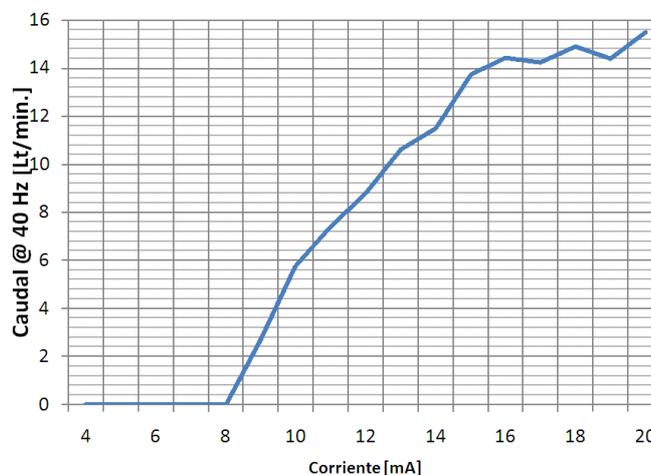


Figura 6. Caudal obtenido variando la corriente a una frecuencia de la bomba de 40 Hz

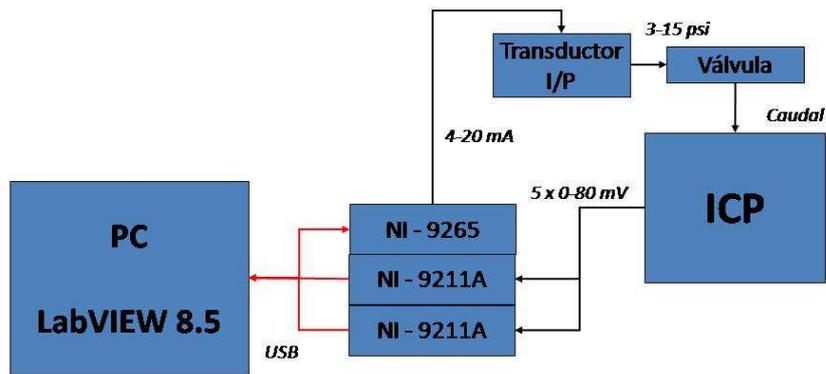


Figura 7. Esquema del sistema de adquisición y control del ICP

El primer modelo implementado fue un control tipo PID sintonizado mediante la técnica de Ziegler – Nichols de respuesta a apertura máxima, para esto, se dejó la válvula cerrada totalmente (a 8 mA) durante 30 segundos y luego se abrió totalmente (20 mA), se esperó entre 70 y 80 segundos mientras estabilizaba el sistema, la reacción en la salida del agua fría se muestra en la

Figura 8.

Las constantes obtenidas fueron:

$$K_p = 22.25, K_i = 1s, K_d = 0.25s$$

Con las constantes del controlador y el .vi de LabVIEW se implementó el PID; mediante técnicas heurísticas se ajustaron las constantes así:

$$K_p = 17.5, K_i = 1s, K_d = 0.25s$$

La prueba de validación del PID consistió en variar la temperatura  $T_d$  deseada empezando en 30 °C y esperar a que la respuesta se estabilice, luego se cambia a 33°C, 27°C, 32°C y 24°C. La respuesta del controlador PID se puede observar en la

Figura 9.

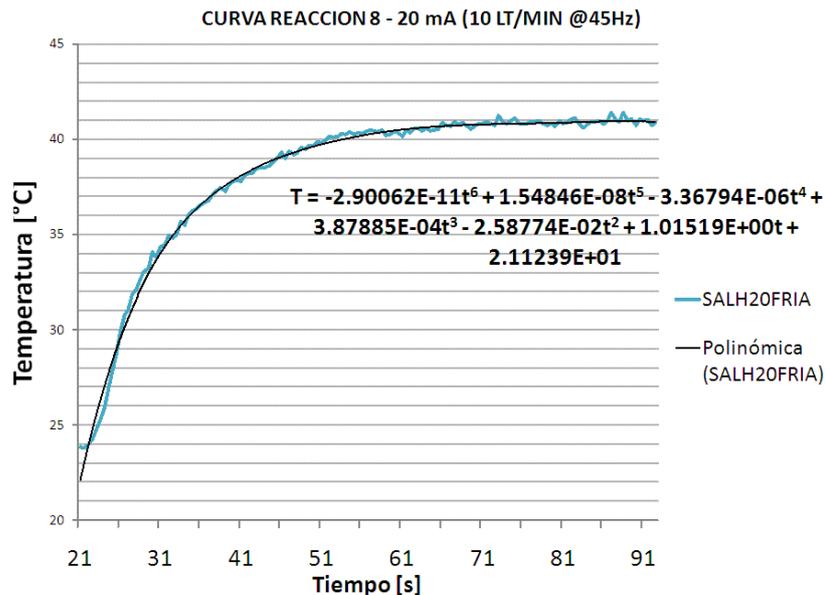


Figura 8. Método de respuesta a escalón para la sintonización del PID

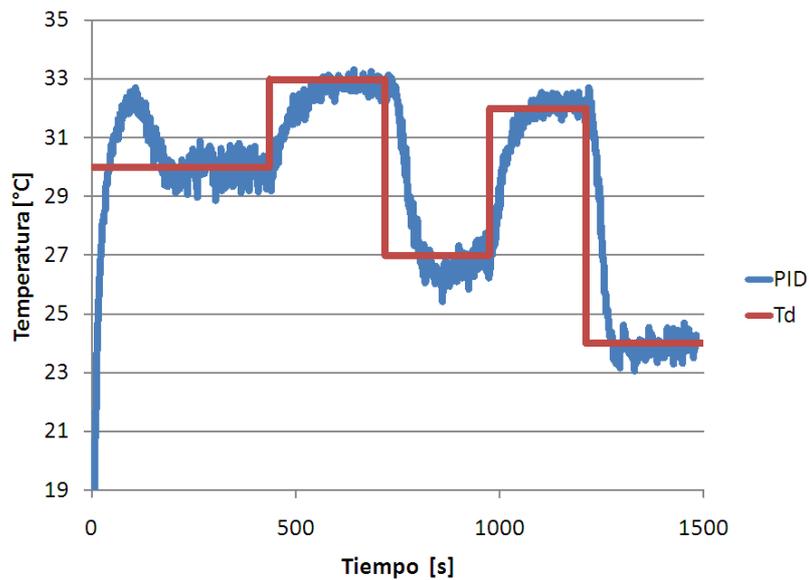


Figura 9. Desempeño del control PID

Posteriormente, se implementó el IMC en LabVIEW como se muestra en el esquema de la Figura 10.

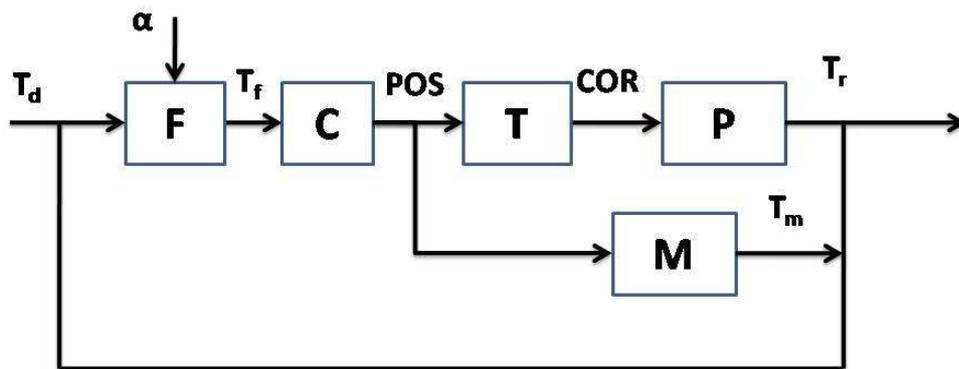


Figura 10. Esquema del IMC implementado en el ICP

Donde:

- $T_d$ : Temperatura deseada [°C]
- $T_f$ : Temperatura a la salida del filtro F [°C]
- $T_r$ : Temperatura real de la planta [°C]
- $T_m$ : Temperatura modelada [°C]
- POS: posición de la válvula [mil]
- COR: señal de corriente [mA]

El filtro robusto F que se usó es tomado de [14], el cual, aunque es lineal, reduce considerablemente el error de modelamiento de  $T_m$  con respecto a  $T_d$ , se sintoniza mediante una única variable  $\alpha$ . Existen diferentes diseños de filtros no lineales incluidos los que usan lógica difusa para auto-ajustarse [6], [8], [12], pero no están dentro del alcance de esta investigación. El filtro F usado, se define como:

$$T_d(t) = T_f(t - 1) + (1 - \alpha) \cdot [T_d(t - 1) - T_r(t - 1) + T_m(t - 1) - T_f(t - 1)]$$

Donde:

- t: unidad de tiempo
- $\alpha$ : parámetro de sintonización, toma valores entre 0 y 1.

Este filtro discreto puede ser interpretado en escala de tiempo continuo como el predictor de Smith [13], [14], a través de la experimentación se obtuvo que para este sistema,  $\alpha=0.9$ .

El operador C y M es tomado a partir de una prueba con el ICP en el que se hizo una variación discreta en la posición de abertura de la válvula y se observaba la estabilización de  $T_r$ , se uso un  $\Delta t = 0.5$  s, se adquirieron 6000 parejas de datos.

Las redes neuronales fueron entrenadas en el programa NNMODEL, el cual utiliza el método de la regla delta generalizada para calcular los pesos de entrada y de salida, que más se ajusten a los datos obtenidos del ICP. Para el operador C, se utilizó el siguiente modelo:

*Entradas*<sup>1</sup>:  
 POS1, POS2, POS3,  $T_{1f}$ ,  $T_{2f}$ ,  $T_{3f}$   
*Salida*:  
 POS  
*Neuronas ocultas*:  
 Cinco

Debido a que a mayor número de neuronas ocultas el entrenamiento se torna más demorado, se optó por usar cinco neuronas ocultas, con lo cual, la red neuronal utilizada sería un perceptron multicapa de tamaño [6|5|1] y fue entrenada con 4800 parejas de datos y validada con 1200. En el entrenamiento, el ajuste fue de  $R^2 = 0.965$  y en la validación de  $R^2=0.955$ . Para el operador M, la red neuronal usada es igualmente una perceptron multicapa de tamaño [6|5|1] con:

*Entradas*:  
 POS1, POS2, POS3, POS4,  $T_{1f}$ ,  $T_{2f}$   
*Salida*:  
 $T_m$

Fue entrenada con 4800 parejas de datos y valida con 1200. En el entrenamiento, el ajuste fue de  $R^2 = 0.995$  y en la validación de  $R^2=0.998$ .

La implementación del IMC fue hecha en LabVIEW y los resultados del IMC están en la Figura 11, donde además se hace una comparación con el control PID antes implementado.

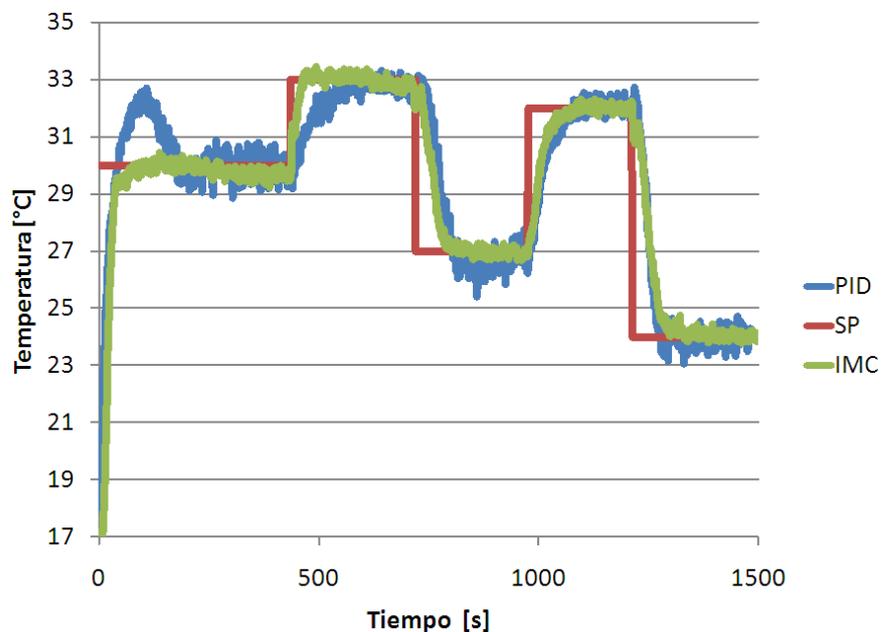


Figura 11. Comportamiento del IMC y comparación con de desempeño del control PID

<sup>1</sup> El número en cada variable indica el número de unidades de tiempo de retraso de la misma.

## 5. CONCLUSIONES

Las redes neuronales aunque son sistemas expertos muy utilizados, tienen una desventaja muy grande y es el tiempo que requiere su entrenamiento para cuando la cantidad de información es muy grande, por lo que se hace necesario establecer sistemas de entrenamiento más eficientes.

El control IMC muestra una menor dispersión en el estado estable, además de un calentamiento más preciso cuando la temperatura deseada se encuentra distante de la temperatura de salida, lo cual es un indicador del mejor desempeño del IMC frente a los controles PID.

Es necesario seguir con el desarrollo de estos sistemas expertos y verificar el uso de filtros no lineales y autoajustables, con el cual se puede lograr que el sistema de control sea totalmente autónomo.

## 6. REFERENCIAS

- [1] H. Xiong. "An Approximate Internal Model-Based Neural Control for Unknown Nonlinear Discrete Processes". IEEE Transactions on neural networks, Vol. 17, No. 3, 2006.
- [2] C. Economou, M. Morari, B. Palsson. Internal Model Control: extension to nonlinear system. Ind. Eng. Chem. Process Des. Dev. Vol 25, pp 403-411, 1986.
- [3] F. Suárez, and J. Zhang. "Improved Bleach Plant Control Using Internal Model Control with Smith Predictor". 16th IEEE International Conference on Control Applications - Part of IEEE Multi-conference on Systems and Control, 2007.
- [4] I. Rivals, L. Personnaz. "Nonlinear internal model control using neural networks: application to processes with delay and design issues". IEEE Transactions on Neural Networks. Vol 11(1), 2000
- [5] C. G. Economou, and M. Morari. Internal Model Control: multiloop design". Industrial & Eng. Chem. Process Design and development. Vol 25 pp 411-419, 1986.
- [6] E. P. Nahas, M. A. Henson, D. E. Seborg. "Nonlinear internal model strategy for neural network models". Computer Chem. Eng. Vol 16, No 12 pp 1039-1057, 1992.
- [7] J. Hilera., V. Martínez. "Redes Neuronales Artificiales" Alfaomega, 2000.
- [8] J. H. Ayala. "Intercambiador de calor de placas diseño y construcción del sistema controlado a través de estrategia PID y adquisición de datos", Tesis de Pregrado, Facultad de Ingeniería, Universidad Nacional de Colombia, 1999.
- [9] F. E. Sierra, "Desarrollo y evaluación de un modelo para controlar un intercambiador de calor basado en redes neuronales", Tesis de Maestría, Facultad de Ingeniería, Universidad Nacional de Colombia, 2000.
- [10] K. Ogata. "Ingeniería de Control Moderna". Tercera Edición. Prentice Hall, 1998.
- [11] L. Torres., G. Hernández., L. F. Niño. "Redes Neuronales", 10° Coloquio distrital de Matemáticas y Estadística - Universidad Nacional de Colombia, 1993.
- [12] W. Yao Nan., Y. Xiao Fang. "SVM Approximate-based Internal Model Control Strategy", ACTA AUTOMATICA SINICA., Vol 34 No 2. February 2008.
- [13] W. Wu, J Xian. "Neural Predictive Control Design for Uncertain Nonlinear Systems". National Yunlin University of Science and Technology, 2004.
- [14] G. Qiang, W. Wei, R. R Xu. "Design of IMC Controller with Anti-Saturation for PMSM Compressor System". IEEE Vehicle Power and Propulsion Conference (VPPC), 2008.

## **7. ABSTRACT**

This article describes the implementation of an IMC (Internal Model Control) nonlinear a plate heat exchanger. For the development of IMC, two models are used to represent a nonlinear plant and one for the inverse of the same (driver), the two systems are implemented using supervised neural networks are multilayer perceptron trained with the inverse propagation technique . Its operation is compared with that of a PID control tuned by the method of Ziegler - Nichols. The tests performed show a proper behavior of IMC at different benchmarks showing a greater stability to sudden changes in the baseline

## **8. NOTICIA DE RESPONSABILIDAD**

**El autor es responsable de la totalidad del contenido de este documento.**