

# Aplicación de las Redes Neuronales para la Identificación de un Sistema no lineal. Un Caso Práctico

Jesús Acosta\* Josep Fernandez\* Lenin Becerra\*\*

\*Departament d'Enginyeria de Sistemes, Automàtica i Informàtica Industrial.  
Universitat Politècnica de Catalunya. Barcelona, España.  
{jacosta,ruzafa}@esaii.upc.es

\*\*Depto. de Ingeniería Electrónica  
Universidad Nacional Experimental Politécnica "Antonio José de Sucre" (UNEXPO). Barquisimeto, Venezuela.  
leninbm@bqto.unexpo.edu.ve

## Resumen

*En el presente trabajo se obtuvieron y analizaron modelos de un sistema de reacción continuo (hidrólisis del anhídrido acético) utilizando las redes neuronales (RN) con el fin de determinar si los mismos realmente presentan un comportamiento dinámico que sea representativo del proceso real. Se compararon tres métodos: el modelo matemático (MM) y dos modelos neuronales desarrollados bajo arquitecturas tipo feedforward: Redes perceptrónicas multicapas (RPM) y redes de base radial. La formulación del MM se basó en el balance de materia para el anhídrido acético, el balance de energía en el reactor y en la expresión de velocidad de reacción. En el patrón de entrenamiento de las RN se incluyeron tiempos de retardo. Para las RPM se usó como método de aprendizaje el Algoritmo Levenberg Marquardt. Todos los modelos obtenidos describieron adecuadamente el comportamiento dinámico real del proceso. Sin embargo, los modelos neuronales dieron mejor aproximación que el MM, y entre ellos, el de base radial lo describió más acertadamente, por lo cual presenta una mayor calidad en la identificación. Estos resultados permitieron comprobar que las RN realmente poseen la habilidad para representar cualquier sistema no lineal, donde la mayoría de los métodos de identificación clásicos no conducen a resultados aceptables.*

**Palabras Claves:** Inteligencia artificial, simulación, algoritmo Levenberg Marquardt, redes neuronales.

## 1 INTRODUCCIÓN

La aplicación de técnicas de control a sistemas dinámicos requieren de una representación que caracterice el proceso físico, o sea, un modelo matemático del mismo. Esta representación

matemática puede obtenerse en forma estrictamente teórica, lo que se denomina *Modelado*; así como también en forma empírica, mediante experimentos sobre el sistema real, basándose en datos de entrada y salida del proceso, llamado *Identificación*.

La principal ventaja del modelado de procesos, es que permite predecir el comportamiento dinámico y estático de los sistemas antes de construirlos y también se puede analizar el desempeño de uno existente, con la intención de estudiar su comportamiento. Además, sin exponer el proceso a daños, se puede determinar que puede ocurrirle, simulando el modelo con una condición, entrada inusual o perturbación.

Para obtener los modelos existen diferentes técnicas de identificación de sistemas. Algunas de ellas requieren medición completa del estado, pero su aplicabilidad se ve limitada ya que esto no siempre es posible, debido a la gran cantidad de no linealidades y perturbaciones presentes en los procesos. Una gran cantidad de los métodos clásicos no conducen a resultados aceptables, por lo tanto, puede ser algunas veces difícil de encontrar modelos matemáticos representativos. Para obviar este problema es necesario hacer uso de observadores ([1]; [2]; [3]; [4]), lo que conlleva a un incremento en la dinámica del sistema. Esto ha llevado a explorar otras técnicas con los cuales se puedan eliminar estos inconvenientes.


Las redes neuronales artificiales o simplemente redes neuronales, constituyen una de las áreas de la inteligencia artificial que ha despertado mayor interés en los últimos años y constituyen una herramienta sumamente general para abordar una amplia clase de problemas de identificación de sistemas dinámicos, como se conoce a través de trabajos realizados por [5]. En particular, este enfoque resulta muy ventajoso cuando se trata de la identificación de sistemas no lineales (como es el caso de todos los procesos

industriales), donde la mayoría de los métodos clásicos no conducen a resultados aceptables. En cambio, las redes neuronales son capaces de resolver problemas cuya solución por otros métodos convencionales resulta extremadamente difícil y/o insatisfactoria.

El presente estudio tiene como objetivo la evaluación de las prestaciones de las redes neuronales para la modelización de un sistema no lineal. En él se analiza un caso práctico: “un sistema de reacción continuo” y se obtienen modelos utilizando las redes neuronales artificiales para determinar si los mismos realmente presentan un comportamiento dinámico que sea representativo del proceso real, asimismo se comparan los resultados de diferentes alternativas de modelización.

## 2 DESCRIPCIÓN DEL SISTEMA DE REACCIÓN CONTINUO

Para la presente investigación se tomó como referencia el sistema de reacción estudiado por [6], el cual es la Hidrólisis del Anhídrido Acético (ecuación (1)), debido a que su naturaleza cumple con todos los requisitos establecidos: es una reacción simple y elemental, en presencia de un exceso de agua, su cinética se ajusta a una expresión de primer orden; asimismo, es una reacción química exotérmica. Sus reactivos (anhídrido acético y agua), así como su producto (ácido acético), son líquidos a presión atmosférica y temperatura ambiente, condiciones a las cuales la reacción puede llevarse a cabo completamente. Además, dicho estudio devela una gran cantidad de datos experimentales, los cuales fueron datos excelentes para el desarrollo de ésta.



Esta reacción química fue llevada a cabo en dos sistemas diferentes, uno continuo y otro discontinuo. La instalación en este caso del sistema de reacción continuo (Véase Figura 1), se realizó con los siguientes elementos: a) Reactor continuo, recipiente cilíndrico con una capacidad de 250 ml (beaker). Operó por rebose, los reactivos se alimentaron empleando un par de buretas de 50 ml, la mezcla reaccionante se mantuvo homogénea con la utilización de un agitador magnético y el producto abandonó el reactor por medio de un canal colocado en la parte superior del mismo (a nivel de la superficie del líquido), b) Termocupla, elemento sensor de temperatura del medio reaccionante, su salida se conectó a un amplificador, con el fin de realizar las mediciones con mayor precisión, y c) Colector, recipiente rectangular empleado para la recolección del producto de la reacción.




Figura 1: Montaje para el Sistema de Reacción Continuo

## 3 FORMULACIÓN DEL MODELO MATEMÁTICO

Se tomaron en cuenta las siguientes consideraciones: a) Las densidades de los reactivos y la del producto permanecen constantes, b) Las capacidades caloríficas del medio reaccionante no varía con los cambios de temperatura y composición, adicionalmente  $C_v$  y  $C_p$  son aproximadamente iguales, c) El calor de reacción es constante en el intervalo de temperaturas de operación, d) Las entalpías de los reactivos se consideran constantes, pues la temperatura de alimentación no cambia, e) La temperatura ambiente permanece constante, y f) El flujo volumétrico del producto permanece constante.

a) *Balance molar en estado dinámico para el reactivo limitante A.*

$$\frac{\rho_A}{PM_A} q_A(t) - Vr_A(t) - q_S C_A(t) = V \frac{dC_A(t)}{dt} \quad (2)$$

donde:

- $\rho_A$ : densidad del anhídrido acético, g/ml.
- $PM_A$ : peso molecular del anhídrido acético, g/mol.
- $q_A(t)$ : flujo volumétrico del anhídrido acético alimentado, ml/seg.
- $V$ : volumen del reactor, ml.
- $r_A(t)$ : velocidad de reacción, mol/ml\*seg
- $q_S$ : flujo volumétrico del producto, ml/seg.
- $C_A(t)$ : concentración del anhídrido acético, g/ml

b) *Velocidad de reacción:*

$$r_A(t) = K_o e^{-E/RT(t)} C_A(t) \quad (3)$$

c) *Balace de energía en el reactor.*

$$H_A \cdot \rho_A \cdot q_A(t) + H_W \cdot \rho_W \cdot q_W(t) - V \cdot r_A(t) \cdot \Delta H_r - U \cdot A(T(t) - T_S) - q_S \cdot \rho \cdot C_p(T(t) - T_{ref}) = V \cdot \rho \cdot C_v \frac{dT(t)}{dt} \quad (4)$$

donde:

$H_A$ : entalpía del anhídrido acético alimentado, Cal/gr.

$\rho_w$ : densidad del agua, g/ml.

$H_w$ : entalpía del agua alimentada, Cal/gr.

$q_w(t)$ : flujo volumétrico del agua, ml/seg.

$\Delta H_r$ : calor de reacción, Cal/mol consumido de A.

U: coeficiente global de transferencia de calor, Cal/cm<sup>2</sup>·°K·seg

A: área de transferencia de calor, cm<sup>2</sup>

$\rho$ : densidad del medio reaccionante, g/cm<sup>3</sup>

$C_p$ : capacidad calorífica del medio reaccionante a presión constante, Cal/g·°K.

$C_v$ : capacidad calorífica del medio reaccionante a volumen constante, Cal/g·°K.

$T_S$ : temperatura ambiente, °K.

$T_{ref}$ : temperatura de referencia para el cálculo de las entalpías, °K.

$T(t)$ : temperatura del medio reaccionante, °K.

*Luego de realizar un proceso de linealización y aplicando Transformada de Laplace se obtiene la siguiente expresión:*

$$C_A(s) = \frac{K_1}{\tau_1 \cdot s + 1} \cdot Q_A(s) - \frac{K_2}{\tau_1 \cdot s + 1} \cdot T(s) \quad (5)$$

$$T(s) = \frac{K_3}{\tau_2 \cdot s + 1} \cdot Q_A(s) + \frac{K_4}{\tau_2 \cdot s + 1} \cdot Q_W(s) - \frac{K_5}{\tau_2 \cdot s + 1} \cdot C_A(s) \quad (6)$$

donde:

T(s): Temperatura del medio reaccionante en el dominio de Laplace

$C_A(s)$ : Concentración del anhídrido acético en el dominio de Laplace.

$Q_A(s)$ : Flujo volumétrico de anhídrido en el dominio de Laplace.

$Q_W(s)$ : Flujo volumétrico del agua en el dominio de Laplace.

$K_1, K_2, K_3, K_4, K_5$ : Ganancias

$\tau_1, \tau_2$ : Constantes de tiempo

*Personalizando el sistema usando los parámetros operacionales y sus propiedades físicas parra determinar las constantes de tiempo y las ganancias, se obtiene el modelo matemático:*

$$C_A(s) = \frac{0,00508}{115 \cdot s + 1} \cdot Q_A(s) - \frac{8,00E-6}{115 \cdot s + 1} \cdot T(s) \quad (7)$$

$$T(s) = \frac{19,74}{270,031 \cdot s + 1} \cdot Q_A(s) + \frac{33,62}{270,031 \cdot s + 1} \cdot Q_W(s) - \frac{(-10.352,9)}{270,031 \cdot s + 1} \cdot C_A(s) \quad (8)$$

## 4 TOPOLOGÍA DE LA RED NEURONAL

Se entiende por topología la configuración física de la red, es decir, la manera en que están interconectados los elementos de procesamiento. Pueden agruparse en dos: a) Redes con topología “feedforward” y b) Redes con topología “with feedback”. En las primeras, las comunicaciones van en una sola dirección, de las neuronas de entrada hacia las neuronas de salida, un ejemplo de este tipo de topología son las redes tipo perceptrón y las redes de base radial. Y en las segundas, algunas neuronas tienen sus salidas conectadas a las neuronas de las capas previas, un ejemplo de estas se ve en las redes recurrentes y las redes Hopfield.

En esta investigación los modelos neuronales se desarrollaron bajo topología tipo feedforward: Redes perceptrónicas multicapas (RNPM) y redes de base radial (RNBR), por ser las más populares y apropiadas para una gran variedad de problemas en ingeniería, con entrenamiento supervisado usándose como método de aprendizaje el Algoritmo Levenberg Marquardt para el primer caso, una mejora al de retropropagación del error (Backpropagation) por las ventajas que éste presenta y porque se probó con otros algoritmos señalados por [7], tales como: Fletcher-Reeves (traincgf), Polak-Ribière (traincgp), Powell-Beale (traincgb), BFGS (trainbfg) y un paso secante (trainoss); pero éstos no convergieron tan rápidamente.

## 5 EXPERIMENTO, RESULTADOS Y DISCUSION

El software utilizado estuvo conformado por los toolboxes “Simulink” y “Redes Neuronales” de Matlab 5.2, el cual permite realizar simulaciones e implementar una gran variedad de redes neuronales facilitando el proceso de investigación. En cuanto al hardware, se usó un computador PENTIUM 200 MMX.

En un principio, se obtuvieron los datos de entrenamiento, éstos debían de cubrir todo el conjunto de entradas esperado, es decir, todo el rango de frecuencia y amplitud de las señales de entrada al sistema. Debido a las características del sistema de reacción estudiado (sistema SISO, Single Input Single Output), para poder ampliar el conjunto de valores que conforman el patrón de entrenamiento

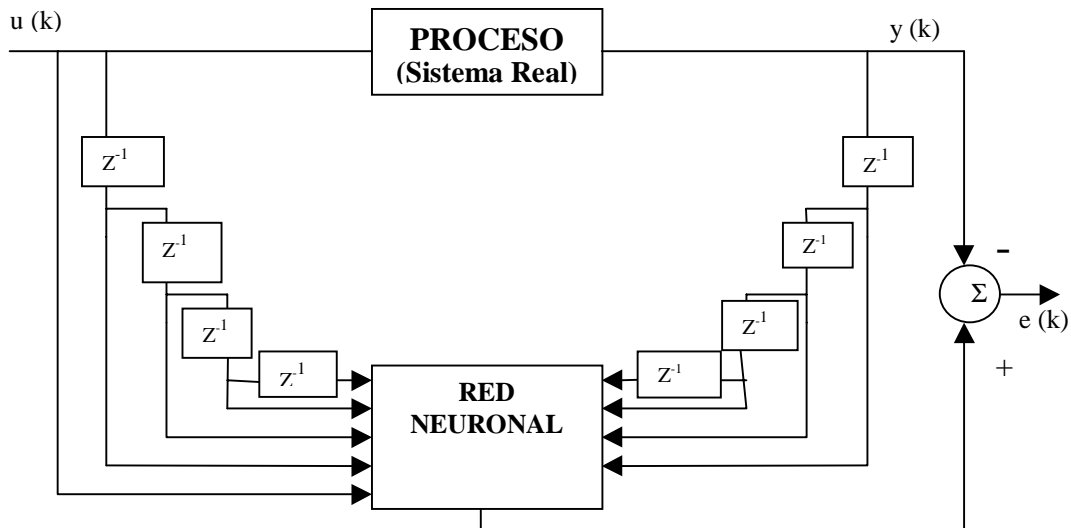


Figura 2: Identificación del proceso en estudio usando Redes Neuronales.

cuando se realizara la simulación, se incluyeron tiempos de retardo de tal manera de obtener suficientes datos históricos del proceso en estudio debido a que sólo se poseían inicialmente treinta y tres pares de datos muestreados, es decir, una entrada con su respectiva salida. Es por ello que el patrón de entrenamiento estaba formado por nueve señales: por la señal de entrada y sus respectivos cuatro retardos, y por cuatro retardos de la señal de salida. Mientras más retardos se agregan se obtiene una mejor aproximación pero conlleva a un mayor tiempo de entrenamiento, menos retardos implica disminuir la calidad de identificación con un entrenamiento rápido. Cada señal contiene una muestra de treinta y tres datos, lo que hace un total de 297 datos muestreados para el patrón de entrenamiento. Esquemáticamente se observa en la Figura 2.

Los parámetros de aprendizaje para la RNPM usados fueron los siguientes: a) Tasa de aprendizaje ( $\alpha$ )=0,005, b) Ciclos de entrenamiento (epochs)=1000, c) Mínimo gradiente = $1e-20$ . En relación a la RNBR fue el Spread (Difusión de la función de base radial) establecido por defecto en 1. Para ambas redes el error medio cuadrático (mse) final fue de 0,001.

Acerca del dimensionamiento de la topología de este tipo de redes, se indica que no existe una teoría que defina a ciencia cierta el número de capas de la red y el número de neuronas en cada capa; esto se hace usando pruebas por ensayo y error. En el caso de las RNPM, se utilizaron tres capas para definir el dimensionamiento de la red: una de entrada, una oculta y otra de salida; y se obtuvo la mejor

combinación de neuronas por capa para el algoritmo de entrenamiento seleccionado, la cual arrojó ser una red con nueve neuronas en la capa de entrada, diez neuronas en la capa oculta y una neurona en la capa de salida. En cambio en las RNBR, se utilizaron dos capas para definir el dimensionamiento de la red: una entrada y otra de salida; el software utilizado diseña redes de éste tipo de dos capas y adiciona neuronas en la capa entrada de la red hasta encontrar la especificación del mse ó alcanzar el máximo número de neuronas, es así como se obtuvo la mejor combinación de neuronas por capa, la cual arrojó ser una red con dieciocho neuronas en la capa entrada y una neurona en la capa de salida. En la Tabla 2, se presentan los resultados obtenidos en el proceso de entrenamiento.

Las funciones de activación utilizadas son diferenciables no lineales (tales como tangente sigmoideal "tansig" para RNPM y base radial "radbas" para RNBR) y lineal (purelin). Después de realizar diferentes pruebas resultó conveniente tanto para la capa de entrada como para la oculta de la RNPM usar tansig y para la capa de salida purelin. En cambio para la RNBR, la capa entrada usó radbas y la capa de salida purelin, en este tipo de red neuronal Matlab fija el tipo de función de activación. Al usar la función tansig ó radbas los datos son escalados (normalizados) para reducir la velocidad de entrenamiento; en cambio en la salida se usa la función purelin y los datos de salida no se transforman. En la tabla 1 se muestran las funciones matemáticas generales que se aplican a una RNBR, en donde:  $n_i = N^\circ$  de neurona (1:N),  $Pr =$  Vector de entrada (1:n),  $w =$  pesos RNBR,  $\theta =$  pesos nodo lineal,  $b =$  bias,  $\hat{y}(k) =$  salida predicha por la red.

Confluencia	$n_i = \sqrt{\sum_r^n (w_{ir} - p_r)^2 \cdot b}$
Función de Activación (Transferencia)	$a_i = \text{radbas}(n_i) = \exp(-n_i^2)$
Función de Salida de Nodo Lineal	$\hat{y}_k = \sum_i^N a_i \cdot \theta_i$

Tabla 1: Funciones matemáticas generales que se aplican en una RNBR.

Modelo	mse obtenido	Tiempo (seg)	Combinación óptima de neuronas por capas
RNPM	0,000995496	79,70	09 10 01
RNBR	0,000011559	2,86	18 01

Tabla 2: Resultados del entrenamiento de las redes neuronales.

MODELO	DESVIACION
Matemático	< 1,5%
Neuronal Perceptrónico Multicapa (NPM)	< 0,40%
Neuronal de Base Radial (NBR)	< 0,05%

Tabla 3: Desviación en % entre los modelos con respecto al proceso real

La asignación de los pesos de las neuronas y sesgos fue asignado automáticamente en ambos casos por el software Matlab.

De los resultados de la Tabla 2 se puede indicar lo siguiente:

- La RNPM obtenida para este problema presentó mayor número de capas que la RNBR. La primera estuvo conformada por tres capas, en cambio la otra estuvo constituida por dos capas.
- Para la RNPM, un mayor número de neuronas en la capa escondida (oculta) aportó mejores resultados en este estudio, lo cual en cierta medida no da cabida a la regla práctica señalada por [8], de que: el número de neuronas de la capa oculta se puede seleccionar aproximadamente igual a la mitad de las neuronas de la capa de entrada. Esto puede ser debido a las funciones de activación utilizadas, es decir, tanto para la capa de entrada como para la oculta se usó tansig y para la capa de salida purelin .
- Tal como lo señaló [9], cuando se inicia el entrenamiento de una RNPM y ésta no converge, se debe comenzar a aumentar el número de neuronas por capas, hasta que se llegue a la combinación óptima con el sistema. Esta situación se dio en el experimento.
- Tal como lo afirma [7], la RNBR necesitó mucho menos tiempo que la RNPM para su diseño. Esto es debido en cierto modo a que la

RNBR estuvo constituida por un menor número de capas: una con dieciocho neuronas (capa de entrada) y otra con una neurona (capa de salida).

- La RNBR presenta un menor error medio cuadrático que la RNPM, por lo cual debe presentar una mayor calidad de identificación.

En la Tabla 3 se muestra el porcentaje de desviación entre los modelos obtenidos con respecto al proceso real. En él se observa que los modelos neuronales presentan menores variaciones que el modelo matemático, esto no significa, que la obtención de un modelo matemático no es instrumento válido para obtener una aproximación a un sistema, sino que en este caso, las redes neuronales se ajustan mejor al comportamiento dinámico del sistema en estudio. Dicha desviación en porcentaje (%) para cada tipo de modelo e instante de tiempo fue calculada mediante las siguientes expresiones matemáticas:

$$\text{Desviación (\%)} = ((T_{\text{mod}_i} - T_{\text{exp}_i}) / T_{\text{exp}_i}) * 100 \quad (7)$$

$$\text{Desviación (\%)} = ((T_{\text{rnp}_i} - T_{\text{exp}_i}) / T_{\text{exp}_i}) * 100 \quad (8)$$

$$\text{Desviación (\%)} = ((T_{\text{rnr}_i} - T_{\text{exp}_i}) / T_{\text{exp}_i}) * 100 \quad (9)$$

donde:

$T_{\text{mod}_i}$ : Temperatura del modelo matemático en el instante de tiempo  $i$ .

$T_{\text{rnp}_i}$ : Temperatura de la red neuronal perceptrónica multicapa (ó de la red neuronal de base radial) en el instante de tiempo  $i$ .

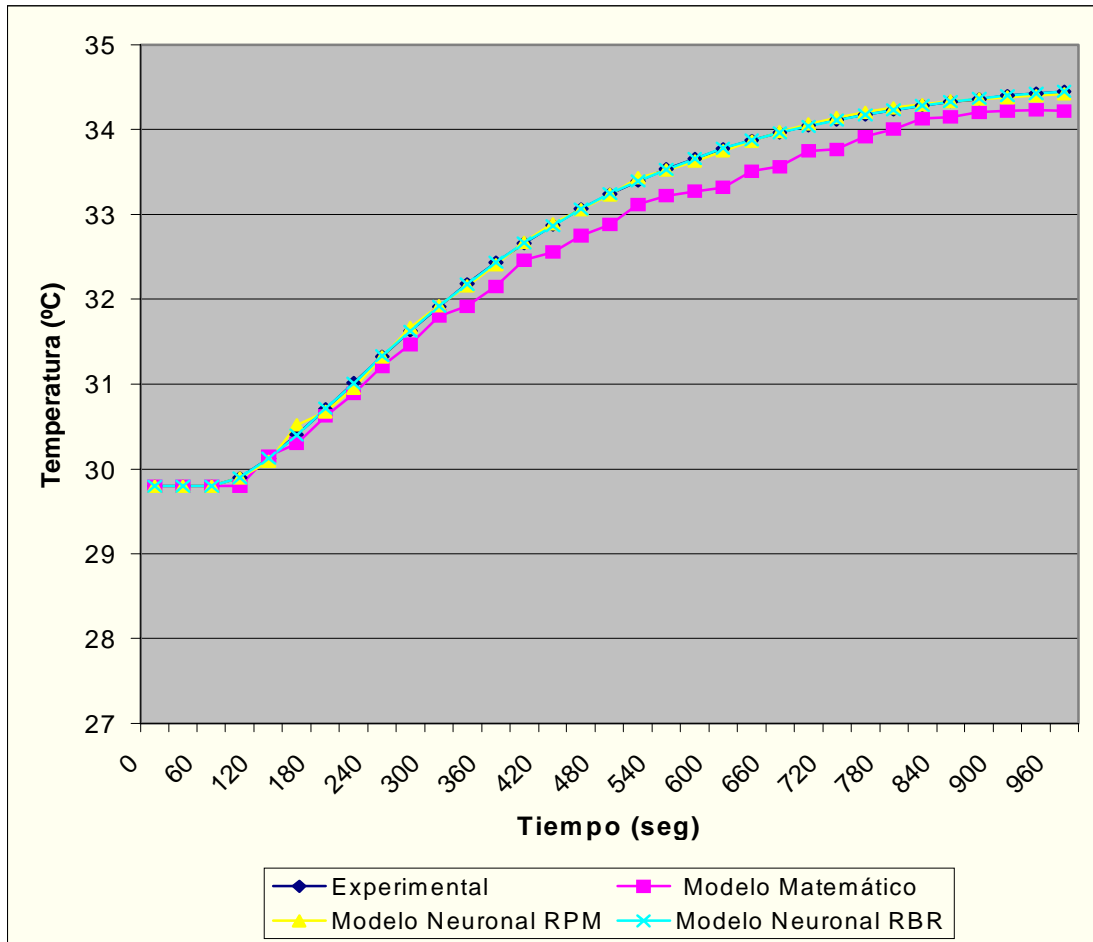


Figura 3: Comparación del proceso real con los modelos obtenidos

$T_{nr_i}$ : Temperatura de la red neuronal base radial en el instante de tiempo  $i$ .

$T_{exp_i}$ : Temperatura experimental en el instante de tiempo  $i$ .

Todos los modelos obtenidos describieron adecuadamente el comportamiento dinámico real del proceso. Sin embargo, los modelos neuronales dieron una mejor aproximación que el modelo matemático, y entre ellos, el de la RNBR lo describió más acertadamente (% de desviación inferior a 0,05), por lo cual presenta una mayor calidad en la identificación (Figura 3).

## 6 CONCLUSIONES Y TRABAJOS FUTUROS

De los resultados del presente estudio se desprenden las siguientes conclusiones:

- La Hidrólisis del anhídrido acético, permitió realizar de manera sencilla, el seguimiento del comportamiento del sistema de reacción, ya que es una reacción exotérmica, homogénea en fase

líquida, que puede llevarse a cabo completamente en condiciones de temperatura ambiente y presión atmosférica. Su cinética se ajusta a una expresión de primer orden.

- La aplicación de simulación para el sistema continuo describió el comportamiento dinámico del mismo, a través de los cambios de concentración del anhídrido acético y la temperatura del medio reaccionante. Fue diseñada en el Toolbox Simulink del software Matlab a partir del modelo matemático.
- Las redes neuronales seleccionadas con topología feedforward (Red Perceptrónica Multicapa y Red de Base Radial), así como los algoritmos de entrenamiento implementados para cada caso, permitieron realizar exitosamente ésta investigación.
- El uso de tiempos de retardos, permitió ampliar el conjunto de valores que conformaron el patrón de entrenamiento cuando se realizó la simulación de las redes neuronales. En otras palabras, tuvo como objeto obtener suficientes datos históricos del proceso en estudio, debido a que sólo se poseen inicialmente treinta y tres pares de datos

muestreados. El patrón de entrenamiento se conformó por nueve señales, lo que dió lugar a 297 datos muestreados.

- El método Levenberg Marquardt convergió más rápidamente que otros algoritmos, tales como: Fletcher-Reeves (traincgf), Polak-Ribière (traincgp), Powell-Beale (traincgb), BFGS (trainbfg) y un paso secante (trainoss); y por eso, además de las ventajas que éste presenta, se seleccionó como algoritmo para entrenar la RNPM.
- El método Levenberg Marquardt no presentó ninguna ventaja evidente sobre el de base radial, esto se debe a su mayor complejidad.
- Tanto el modelo matemático formulado para el sistema de reacción continuo como los modelos neuronales, describieron adecuadamente su comportamiento dinámico real. Sin embargo, los modelos neuronales dieron una mejor aproximación que el modelo matemático.
- Entre los modelos neuronales el de base radial describió más acertadamente el comportamiento dinámico real, por lo cual presenta una mayor calidad en la identificación.

En resumen, se puede señalar que los modelos neuronales realmente presentan un comportamiento dinámico representativo del proceso real. Esta ventaja es aplicable tanto a modelos lineales como a no lineales, ya que es una habilidad de éstas representar cualquier función lineal o no entre una data de entrada y una de salida.

Como trabajo futuro se piensa realizar:

- La aplicación de las redes neuronales con topología “with feedback” (entre ellas redes recurrentes y redes de Hopfield), para la identificación del mismo proceso en estudio, con el objeto de observar si aportan mejores resultados que las redes con topología feedforward (Redes perceptrónicas multicapas y redes de base radial).

## Referencias

- [1] Anstrom, K. J. And Wittenmark, B., (1995) Adaptive Control, Addison Wesley.
- [2] Franklin, G. et al. (1994) Digital Control of Dynamic Systems, Addison Wesley.
- [3] Ioannou, P. And Sun, J., (1996) Robust Adaptive Control, Prentice Hall.
- [4] Mosca, E. (1995) Optimal Predictive and Adaptive Control, Prentice Hall.
- [5] Narendra, Kumpati et al. (1990) “Identification and Control of Dynamical Systems using Neural Networks”, IEEE Transactions on Neuronal Networks, Vol. 1, Nº 1, pp. 4-27.
- [6] Suárez, J. Y Lucena, M (1998) Estudio de la Estabilidad de un Sistema de Reacción mediante simulación dinámica. Universidad Nacional Experimental Politécnica “Antonio José de Sucre” (UNEXPO), Departamento de Ingeniería Química. Barquisimeto, Venezuela.
- [7] Demuth, H. and Beale, M. (1997) Neural Network Toolbox for Use with MALTLAB®: User’s Guide Version 3.0, U.S.A., The MathWorks, Inc.
- [8] Aguado, A. y Otros (1998) “Identificación de sistemas dinámicos no lineales mediante redes neuronales”, Instituto de Cibernética, Matemática y Física de la Habana-Universidad Autónoma de Querétaro de México, III Congreso de la Asociación Colombiana de Automática, Colombia.
- [9] Angulo, F. y Delgado, A. (1998) “Identificación de sistemas dinámicos no lineales con redes neuronales recurrentes”, Universidad Nacional de Colombia, III Congreso de la Asociación Colombiana de Automática, Colombia.